



VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ

BRNO UNIVERSITY OF TECHNOLOGY

FAKULTA PODNIKATELSKÁ

FACULTY OF BUSINESS AND MANAGEMENT

ÚSTAV EKONOMIKY

INSTITUTE OF ECONOMICS

MODELOVÁNÍ PREDIKCE BANKROTU
ZEMĚDĚLSKÝCH PODNIKŮ

BANKRUPTCY PREDICTION MODELLING IN THE AGRICULTURE BUSINESS

DIPLOMOVÁ PRÁCE

MASTER'S THESIS

AUTOR PRÁCE

AUTHOR

Bc. Petr Pokorný

VEDOUCÍ PRÁCE

SUPERVISOR

Ing. Michal Karas, Ph.D.

BRNO 2017

Zadání diplomové práce

Ústav: Ústav ekonomiky
Student: **Bc. Petr Pokorný**
Studijní program: Ekonomika a management
Studijní obor: Podnikové finance a obchod
Vedoucí práce: **Ing. Michal Karas, Ph.D.**
Akademický rok: 2016/17

Ředitel ústavu Vám v souladu se zákonem č. 111/1998 Sb., o vysokých školách ve znění pozdějších předpisů a se Studijním a zkušebním řádem VUT v Brně zadává diplomovou práci s názvem:

Modelování predikce bankrotu zemědělských podniků

Charakteristika problematiky úkolu:

Úvod
Cíl a metody zpracování práce
Teoretická východiska predikce bankrotu a popis testovaných modelů
Zhodnocení současné efektivnosti vybraných bankrotních modelů na zkoumaném vzorku podniků
Návrh vlastního bankrotního modelu
Srovnání efektivnosti vytvořeného modelu a vybraných modelů
Závěr
Seznam použité literatury
Přílohy

Cíle, kterých má být dosaženo:

Cílem práce je zhodnotit rozlišovací schopnost pěti vybraných bankrotních modelů a její porovnání s původně deklarovanou přesností. Metodou lineární diskriminační analýzy odvodí vlastní model a provede testování jeho rozlišovací schopnosti.

Základní literární prameny:

ALTMAN, E. I. and G. SABATO. Modelling Credit Risk for SMEs: Evidence from the U.S. Market. Abacus. 2007, vol. 43, no. 3, s. 332-357. ISSN 0001-3072.

BIELIKOVÁ, T., T. BÁNYIOVÁ and A. PITERKOVÁ. Prediction Techniques of Agriculture Enterprises Failure. Procedia Economics and Finance. 2014, vol. 12, s. 48-56. ISSN 2212-5671.

GRICE, J. S. and M. T. DUGAN. The limitations of bankruptcy prediction models: Some cautions for the researchers. Review of Quantitative Finance and Accounting. 2001, vol. 17, no. 2, s. 151-166. ISSN 1573-7179.

LUKASON, O. Why and how agricultural firms fail: evidence from Estonia. Bulgarian Journal of Agricultural Science. 2014, vol. 20, no. 1, s. 5-11. ISSN 1310-0351

NEUMAIEROVA, I. a I. NEUMAIER. Index IN05. In: ČERVINEK, P. (ed.). Evropské finanční systémy. Brno: Masarykova univerzita, 2005. s.143-148. ISBN 80-210-3753-9.

Termín odevzdání diplomové práce je stanoven časovým plánem akademického roku 2016/17

V Brně dne 28.2.2017

L. S.

doc. Ing. Tomáš Meluzín, Ph.D.
ředitel

doc. Ing. et Ing. Stanislav Škapa, Ph.D.
děkan

ANOTACE

Diplomová práce je zaměřená na problematiku predikce bankrotu firem podnikající v odvětví zemědělství v České republice. Úvodní část se skládá z úvodu do odvětví zemědělských firem a teoretického popisu modelů bankrotu využívaných v akademické praxi. Praktická část práce je rozdělena do dvou úseků. V prvním je provedena aplikace dat dostupných z veřejných zdrojů do určitých modelů bankrotu a jejich hodnocení. Následující úsek je zaměřen na zdokonalení nejslibnějšího modelu s cílem maximalizovat jeho přesnost.

ANNOTATION

This master's thesis is focused on problematic within the prediction of bankruptcy of companies operating in the field of agriculture in Czech republic. First part consists of introduction to companies that do business in field of agriculture and it describes bankruptcy models that are used in academics sphere. Other part of thesis is divided into two sub-parts. First part is dedicated to an application of data into models of bankruptcy and their evaluation. Second part is focused on improvement of the best model and its main goal is to maximize the precision of the bankruptcy.

KLÍČOVÁ SLOVA

Bankrot, model, predikce, finanční ukazatele, zemědělství, statistická analýza, data, testování přesnosti, ROC křivka, váhy proměnných, meze, korelace

KEY WORDS

Bankruptcy, model, prediction, financial indexes, agriculture, statistical analysis, data, percision testing, ROC curve, weight of ratio, limits, correlation

BIBLIOGRAFICKÁ CITACE

POKORNÝ, P. Modelování predikce bankrotu zemědělských podniků. Brno: Vysoké učení technické v Brně, Fakulta podnikatelská, 2015. 91 s. Vedoucí diplomové práce Ing. Michal Karas, Ph.D.

ČESTNÉ PROHLÁŠENÍ

Prohlašuji, že předložená diplomová práce je původní a zpracoval jsem ji samostatně. Prohlašuji, že citace použitých pramenů je úplná a že jsem ve své práci neporušil autorská práva (ve smyslu zákona č. 121/2000 Sb., o právu autorském a o právech souvisejících s právem autorským).

V Brně, dne 26. května 2017

PODĚKOVÁNÍ

Děkuji všem kteří mě podporovali a pomáli při cestě k sepsání této práce. Zvláště chci poděkovat Ing. Michalu Karasovi, Ph.D. za vedení a ochotu.

OBSAH

ÚVOD	11
1. CÍL A METODY ZPRACOVÁNÍ PRÁCE	12
2. TEORETICKÁ VÝCHODISKA PREDIKCE BANKROTU	14
2.1. Výběr proměnných modelu a jejich optimalizace	14
2.1.1. Korelační analýza.....	15
2.2. Metody tvorby modelů	15
2.3. Matematicko-statistické metody.....	16
2.3.1. Logistická regrese	16
2.4. Jednorozměrná analýza	17
2.5. Risk index modely	18
2.6. Lineární diskriminační analýza	19
2.7. Modely podmíněné pravděpodobnosti	21
2.8. Metoda klasifikačních stromů	22
2.9. Problémy parametrických modelů.....	22
2.10. Multivariate adaptive regression spline (MARS)	24
2.11. Neuronové sítě	25
2.12. Hybridní modely	26
2.13. Určení šedé zóny.....	27
3. POPIS TESTOVANÝCH MODELŮ.....	28
3.1. Historie vývoje modelů bankrotu	29
3.2. Modely bankrotu	31
3.3. Beaverova analýza.....	31
3.4. Altmanovo Z – skóre	32
3.5. Tafflerův bankrotní model.....	37

3.6.	Zmijewski model	38
3.7.	Altman Sabato model	38
3.8.	Indexy IN	40
4.	ZHODNOCENÍ SOUČASNÉ EFEKTIVNOSTI VYBRANÝCH BANKROTNÍCH MODELŮ NA ZKOUMANÉM VZORKU PODNIKŮ	43
4.1.	Malé a střední podniky (SME)	43
4.2.	Analyzované odvětví	44
4.3.	Vzorek	45
4.4.	Vybrané modely a jejich přesnosti	45
4.4.1.	Index IN 05	46
4.4.2.	Altmanovo Z skóre 1977	48
4.4.3.	Altmanovo Z skóre 1983	50
4.4.4.	Altman Sabato model	52
4.4.5.	Altman Sabato model logaritmovaný	53
4.4.6.	Celkové hodnocení modelů	55
5.	NÁVRH VLASTNÍHO MODELU BANKROTU	60
5.1.	Testovací vzorek	60
5.2.	Podílové ukazatele	60
5.3.	Korelace	61
5.4.	Tvorba modelů	62
5.4.1.	Model $X(n1)(d)$	63
5.4.2.	Model $X(n1)(z)$	65
5.4.3.	Model $X(n2)(d)$	66
5.4.4.	Model $X(n2)(z)$	68
5.4.5.	Model $\log(X(n)+50)(d)$	69
5.4.6.	Model $\log(X(n)+50)(z)$	71

5.5.	Porovnání vytvořených modelů.....	72
5.6.	MODEL ₃ - X(n ₂)(d).....	74
5.7.	MODEL ₆ – log(X(n)+50)(z).....	77
6.	SROVNÁNÍ EFEKTIVNOSTI VYTVOŘENÝCH A VYBRANÝCH MODELŮ	81
	ZÁVĚR	84
	SEZNAM POUŽITÝCH ZDROJŮ	85
	SEZNAM POUŽITÝCH ZKRATEK.....	88
	SEZNAM OBRÁZKŮ	89
	SEZNAM GRAFŮ.....	89
	SEZNAM TABULEK	90

ÚVOD

Úpadek firmy neboli bankrot je součástí života podniku. Firmy, které přestanou ignorovat a hlídat si konkurenci, nejsou připraveny na náhlé změny poptávky nebo podcení okolní vlivy mohou snadno zbankrotovat. Bankrot v mnoha případech není okamžitý. Je to dlouhodobý proces špatných rozhodnutí, náhod a nedopatření, které vedou k vyčerpání kapitálu, morálky zaměstnanců a důvěry obchodních partnerů. Pro predikci úpadku firmy lze použít bonitně bankrotní modely. Modely mají za hlavní cíl včasnou identifikaci hrozícího bankrotu. Pokud jsou úspěšné, může vedení podniku včas přeskupit své síly, optimalizovat svoje závazky, stanovit důležité procesy, zavést opatření a začít hledat alternativní zdroje financování. Nápravná opatření a správně stanovené procesy vedou k obnovení důvěry věřitelů a odběratelů.

Ve stále rychleji se rozvíjejícím světě setrvává zemědělství na horní příčce důležitých odvětví, jak v ekonomice, tak pro člověka samotného. Každý den je potřeba, aby zemědělské firmy vyráběly a prodávaly své produkty na domácích i zahraničních trzích. Z tohoto důvodu je nutné, aby dokázaly co nejrychleji identifikovat, pokud se ocitnou v úpadku ony sami nebo mají problémové dodavatele, odběratele či investory. Bankrotní modely však nejsou bez chyb. Přesnost zavedených modelů se výrazně liší u jednotlivých ekonomických odvětví. Druhým problémem je fakt, že většina těchto modelů vznikala za úplně jiných podmínek, než ve kterých se pohybují dnešní podniky. Poslední vítkou je pak obrovský rozdíl mezi modely vznikající v tuzemských a zahraničních podmínkách. Z těchto důvodů je nutno hledat nové cesty, jak identifikovat faktory pro měření úpadku zemědělských podniků v různých časových obdobích. Nejlepším modelem totiž je takový, který dokáže odhalit možný úpadek mnoho let dopředu.

1. CÍL A METODY ZPRACOVÁNÍ PRÁCE

Tato kapitola obsahuje cíl a metody zpracování diplomové práce. Zároveň popisuje jednotlivé typy metod a jejich použití v kapitolách. Dílčí částí je formulace výzkumných otázek a zamyšlení, které by měly v průběhu práce být zodpovězeny.

Cíl práce je zhodnotit rozlišovací schopnost pěti vybraných bankrotních modelů a její porovnání s původně deklarovanou přesností. Metodou lineární diskriminační analýzy je odvodit vlastní model a provést testování jeho rozlišovací schopnosti.

Metody zpracování práce se vztahují hlavně k praktické části práce. Jedná se především o tyto:

- **Statistické testy a metody** – neparametrická korelační analýza s výslednou podobou spearmanova koeficientu korelace, statistická šetření, zpracování dat zjištění četnosti, a dále hodnocení a optimalizace binárního klasifikačního systému.
- **Syntéza** – při tvorbě modelu z vybraných poměrových ukazatelů.
- **Analýza** – pro rozklad a rozbor jednotlivých modelů a celkového vzorku dat
- **Komparace** – porovnávání jednotlivých bankrotních modelů, jednotlivých ukazatelů a přesností při stanovení optimální šedé zóny.
- **Vědecký popis** – celkový popis modelů, jejich přesnot na celkovém a testovacím vzorku

Pro využití metody lineární nebo vícerozměrné diskriminační analýzy a odvození vlastního modelu je potřeba následujících metod:

- Výběr a analýza poměrových ukazatelů
- Korelace vybraných podnikových ukazatelů
- Diskriminační analýza
- Výběr ukazatelů s největším příspěvkem k rozlišovací schopnosti modelu
- Výpočet váhy jednotlivých ukazatelů
- Sestavení modelů bankrotu a jejich testování
- Výběr modelu s největší přesností
- Určení hranic a tzv. šedé zóny
- Testování výsledného modelu

Formování výzkumných otázek - kromě jasně vytyčeného cíle je potřeba najít odpovědi na tyto otázky:

1. Jsou vybrané bankrotní modely dostatečně přesné v podmínkách českého zemědělství?
2. Jsou vybrané bankrotní modely lepší než modely vytvořené během této práce?

Výzkumná otázka č.1. – jsou vybrané bankrotní modely dostatečně přesné v podmínkách českého zemědělství? Pro jasnou odpověď je nutno vytvořit bodový systém založený na přesnosti modelů a jejich aplikovatelnosti na vzorku dat.

Výzkumná otázka č.2. - Jsou vybrané bankrotní modely lepší než modely vytvořené během této práce? Pro odpověď na tuto otázku je potřeba aplikovat bodový systém z předchozího bádání na vytvořené modely. Tento čin povede ke kompletnímu hodnocení vybraných a vytvořených modelů a tudíž i k porovnání.

2. TEORETICKÁ VÝCHODISKA PREDIKCE BANKROTU

Základem predikce bankrotu a tvorby modelů je volba správného postupu, důvěryhodných informací a kvalitního modelování. Modelování získává v posledních letech velký význam téměř ve všech technických a přírodovědeckých oborech. Do modelování, stejně jako jiných odvětví vědy proniklo již od šedesátých let minulého století využití výpočtní techniky. V dnešní době si tvorbu modelů bez počítače nedokáže téměř nikdo představit. Díky pokroku je možné využívat nejen parametrické, ale i neparametrické přístupy s mnoha faktory, proměnnými a výpočty. I přes dokonalou techniku je potřeba dodržovat určité postupy a zákonitosti, aby modely stihly držet krok s turbulentním prostředím. Autoři při tvorbě si stanovují určité požadavky a cíle.[6][21]

Požadavky na kvalitní predikční model:

- Maximální predikční síla
- Maximální interpretovatelnost
- Minimální složitost

2.1. Výběr proměnných modelu a jejich optimalizace

Výběr proměnných nelze považovat za čistě náhodný proces. Vše v modelování má svá pravidla. Na začátku je dostačující využít většinu ukazatelů, které nabízí finanční analýza. Tyto ukazatele vypočítat pro jednotlivé podniky není problém. Ten nastává pokud by autoři chtěli použít všechny. Model by se stal velmi chaotický. Je potřeba zredukovat proměnné pouze na vzorek s největší vypovídací schopností. Otázkou tedy zůstává, jak tyto proměnné vybrat. Dle odborné literatury existují alespoň dva přístupy. Prvním je na základě frekvence ukazatele v literatuře a druhý je dle míry statisticky významného vlivu.

Frekvence ukazatele v literatuře

Na základě převládajícího názoru v literatuře jsou vybrány ukazatele, které nejlépe popisují danou oblast hospodaření podniku. Příkladem může být E. Altman, tedy oblasti renability, aktivity, likvidity a zadlužení. Tento přístup není dokonalý. Vytváří otázky kolem nesrovnalostí různých studií, protože některé navrhuji jiné ukazatele.

Míra statisticky významného vlivu

Model je vytvořen na základě proměnných s dostatečnou vypovídající schopností. Je určen seznam ukazatelů a ty jsou testovány a přidávány do modelu pouze pokud disponují velkou statistickou závislostí. Tento postup používají hlavně regresivní analýzy, kdy počet proměnných optimalizuje právě příspěvek k vypovídací schopnosti modelu. Tvorba modelů musí tedy zahrnovat pravidla:

- Neobsahuje redundantní¹ proměnné
- je otestován na nezávislých datech
- má statisticky nebo jinak významné proměnné [9]

2.1.1. Korelační analýza

Korelace vyjadřuje vzájemný vztah mezi dvěma procesy nebo veličinami. Pro většinu modelů je důležitá korelace mezi dvěma veličinami popřípadě ukazateli. Pokud se jeden z ukazatelů změní, pak podobně korelovaný ukazatel, provede podobné. Korelace tedy znamená souvislost, ale nelze ji považovat za kauzalitu. Kauzální veličina nemusí být nutně korelovaná a naopak. Při sestavování modelu je na tento fakt potřeba brát ohledy. Korelace může nabývat hodnot od +1 do -1, kde kladné číslo znamená přímou závislost mezi veličinami a záporné číslo pak závislost nepřímou. Pro veličinu, která disponuje nulovou korelací v návaznosti na jinou, pak můžeme říci jenom, že tyto veličiny se neovlivňují. [25]

2.2. Metody tvorby modelů

Vedle finální analýzy existuje řada nástrojů a metod, jež se snaží zmapovat finanční situaci podniku. Vícerozměrné modely pracují i s několika kritérii zároveň a výsledkem je pak přiřazení konkrétní váhy určitým ukazatelům a odvození stupně finančního zdraví. Tvorba modelů se skládá z více částí. Část první kromě nezbytného zajištění dat, je určení proměnných modelu. V druhé části je model centrován a vyvažován, aby určil a predikoval, co nejvíce bankrotních a nebankrotních podniků. Při tvorbě modelů se pracuje s parametrickými a neparametrickými metodami. Rozdílem těchto metod je především předpoklad normálního rozdělení vstupních dat.

¹ Redundantní - nadbytečné

Parametrický přístup

Mezi nejčastěji aplikované parametrické metody patří:

- Matematicko statistické metody
- Jednorozměrná analýza
- Risk index modely
- MDA – vícenásobná lineární diskriminační analýza

Neparametrický přístup

„Rozmach počítačů, který se začal v 90. letech, umožnil použití složitějších, početně náročnějších metod umělé inteligence (umělé neuronové sítě, fuzzy modely, generické algoritmy apod.), ty vynikají větší přesností predikce, než jakou by dosáhly předchozí modely“. [12]

- MARS
- NN
- Hybridní modely

2.3. Matematicko-statistické metody


Matematicko statistické metody byly dlouhou řadu let považovány za základní kámen při tvorbě jednoduchých diskriminačních analýz. Principem metod je rozdělení společností na upadající a finančně zdravé. *V matematickém modelu uvažujeme základní skupiny proměnných: rozhodovací (řídící) proměnné, vstupní (exogenní) proměnné, stavové proměnné, náhodné proměnné a výstupní (endogenní) proměnné.* Náhodné proměnné jsou obvykle určeny pravděpodobnostní funkcí (diskrétní proměnná) nebo hustotou pravděpodobnosti (spojitá proměnná) a představují neurčitost v modelu.[10]

2.3.1. Logistická regrese

Logistická regrese umožňuje analýzu dat, kdy odezva je binární, nebo frekvenční veličina vyjádřená hodnotami nula nebo jedna, případně poměry v intervalu od nuly do jedné. Poměry představují podíl pozitivních výsledků v případě více opakovaných měření při téže hodnotě nezávislé proměnné x . Měření by mělo přitom být pro každý poměr podobné. „Logistická regrese se používá při modelování pravděpodobnosti v závislosti

na hodnotě spojité proměnné. Předpokládá se, že náhodná proměnná má binomické rozdělení s parametrem π , který odpovídá pravděpodobnosti výsledku „1“ a mění se monotónně s hodnotou nezávislé proměnné. Výsledný model je právě odhadem tohoto parametru v závislosti na x . Použití logistického modelu je velmi široké a zahrnuje řadu velmi rozdílných oborů.“[4]

Obrázek 1: Lineární regrese



Zdroj: Literatura - MARS [4]

2.4. Jednorozměrná analýza

V roce 1967 W. Beaver aplikoval první jednorozměrný model – jednorozměrnou diskriminační analýzu na výsledky poměrových ukazatelů finanční analýzy a porovnával jednotlivé výsledky. Porovnání spočívalo ve srovnání výsledků poměrových ukazatelů pro aktivní – finančně zdravé podniky a bankrotní – finančně nezdravé podniky, s cílem definice modelu predikce úpadku. Pro výběr konkrétního modelu si Beaver vypomohl aplikací dichotomického² klasifikačního testu, za účelem identifikace ukazatelů s největší výpovědní schopností a přidanou hodnotou.

V jednorozměrných modelech úpadku je kladen důraz na signály naznačující úpadek. Tvůrce modelu provádí, popřípadě počítá samostatně každou hodnotu či ukazatel obsažený v modelu. Při hodnocení společnosti je poté každý ukazatel vyhodnocen

² Dichotomie (z řeckého dica = na dvakrát a tome = řez) je obecně jakékoli rozdělení celku do dvou vzájemně se nepřekrývajících částí.

samostatně a pomocí mezního nebo průměrného bodu tohoto ukazatele je společnost hodnocena jako aktivní nebo bankrotní. V obecné rovině platí, že pokud mezní ukazatel je větší než ukazatel podniku, je firma vyhodnocena jako bankrotní a naopak pokud ukazatel podniku výrazně překročí hranici mezního ukazatele, je firma hodnocena jako finančně zdravá. Spolehlivost je měřena pomocí procenta chyb prvního a druhého stupně. Největší výhodou modelů tohoto typu je jejich jednoduchá interpretovatelnost. Predikce úpadku nevyžaduje žádné zvláštní či hlubší statistické znalosti a metody. Jde pouze o porovnání mezní a výsledné veličiny a na tomto základě vyhodnotit zdraví podniku. Určitou slabinou této metody je fakt, že bez lineární závislosti dat konkrétních ukazatelů popřípadě hodnot není možné výsledky správně vyložit. U finančně zdravých podniků je celkem běžné, že tato lineární závislost u jednotlivých ukazatelů existuje, naproti u bankrotních společností se data, ukazatele i hodnoty značně liší, rostou a kolísají v nelineárních trendech. V praxi se tudíž tato metoda pro bankrotní podniky nedá efektivně využít bez dalších statistických analýz. Druhým nedostatkem jednorozměrné analýzy je problém nekonzistence. Při hodnocení společností je brána hodnota konkrétního poměrového ukazatele v ten daný moment, což může v důsledku vést k zmateným a nesouvislým výsledkům v rámci jednoho podniku.[25]

2.5. Risk index modely

M. Tamari si v roce 1966 uvědomil, že pro posouzení finančního zdraví firmy se nemůžeme opírat pouze o jednu proměnnou u jediného ukazatele. Poukázal na skutečnost, že díky problému silné nekonzistence a malé výpovědní schopnosti osamocенého ukazatele je velmi obtížné získat přehled o finančním zdraví. Tyto důvody jej vedly k vytvoření „risk index“ modelu. Jde o jednoduchý bodový systém, který zahrnuje různé poměrové ukazatele, všeobecně akceptovatelné v akademicko – vědeckém prostředí, jako jsou ukazatele rentability, likvidity a aktivity. Pomocí tohoto systému Tamari přiřadil sumu od 0 – 100 bodů. Čím vyššího skóre byl podnik schopen dosáhnout, tím lépe byla hodnocena jeho finanční situace a zdraví. K tomu, aby systém fungoval efektivně, vytvořil autor i jednoduchý váhový systém, přidělující k jednotlivým ukazatelům váhu, kterou podle něj ovlivňují celkový počet bodů. [25]

Pokročilým risk index modelem je pak práce Moses & Liao z roku 1987. Jejich risk index staví na klasické jednorozměrné analýze kombinované s váhovým systémem Tamariho

modelu. Využívá tedy jednoduchosti porovnání mezních a výsledných hodnot poměrových ukazatelů a přiřazení buď jednoho nebo žádného bodu v závislosti na ukazateli. Podobně jako u předešlého váhového modelu, čím větší součet bodů na konci, tím lépe pro podnik.[25]

2.6. Lineární diskriminační analýza

Lineární diskriminační analýza, z anglického „*Linear Discriminant Analysis*“, dále jen LDA, je statistickou metodou využívající klasifikace jednotlivých veličin do několika skupin v závislosti na charakteristických vlastnostech těchto veličin. Pokouší se odvodit lineární nebo kvadratické kombinace těch veličin, které nejvhodněji tyto skupiny odlišují. V LDA modelech jsou nejrozličnější ukazatele a proměnné kombinovány do jednoho vícerozměrného diskriminačního pole D_i . Výsledkem je jednorozměrová kalkulace s hodnotou v reálných číslech, která nám dává určitou představu o finančním zdraví podniku. Tato kalkulace má možnost více variant. Jde o tzv. krokové analýzy. Proměnné jsou testovány na základě jejich příspěvku k modelu a to buď dopřednou krokovou analýzou – přidá se první proměnná a poté další, model je pokaždé znovu testován, nebo zpětnou analýzou – z modelu jsou postupně odebrány proměnné.

$$D_i = D_0 + D_1 X_{i1} + D_2 X_{i2} + \dots + D_n X_{in}$$

Kde D_i je diskriminační skóre pro společnost „i“ (v intervalu $-\infty$ až $+\infty$),

X_{ij} – hodnota proměnné X_j (kde $j = 1, \dots, n$) pro společnost i ,

D_j – Lineární diskriminační koeficient (kde $j = 0, 1, \dots, n$).

Přesnost, nazývaná někdy také, klasifikační přesnost, či spolehlivost LDA modelu je posuzována dle počtu odchylek nebo chyb. Ve výpočtu se můžeme setkat se dvěma typy chybovosti. Chyba prvního stupně – často označována v modelech chyba I. je chybné rozhodnutí, poté co analýza odmítne pravdivou hypotézu a uvěří falešnému poplachu. Tato chyba, ač velmi častá, nemá velký dopad na model. Druhou, vzácnější a závažnější, je chyba druhého řádu, označována často chyba II. Jde o tzv. přehlédnutou hrozbu, kdy analýza určí hypotézu jako pravdivou, ale ta ve skutečnosti vůbec není. V bankrotních modelech je chyba druhého řádu závažným pochybením a při velkém počtu je model označen za nepřesný. [7]

Wilks lambda měří odlišnost v pozici centroidů skupin definovaných danými proměnnými. Je počítána jako poměr determinantů matice sumy čtverců a vektorového součinu W a T , kde W je složená matice sumy čtverců uvnitř každé analyzované skupiny a T je matice skalárních produktů centrovaných proměnných pro všechny objekty bez ohledu na to, z jaké skupiny pochází. [11] Tento poměr má rozsah, který lze vyjádřit na intervalu od nuly – maximální rozdíl až jedničku, která představuje žádný rozdíl mezi centroidy skupin. Aby mohla být Wilks lambda statisticky testována, musí být převedena na chi-square nebo F statistiku.

Mahalanobisova vzdálenost „jde o obecné měřítko délky beroucí v úvahu korelaci mezi parametry a je nezávislá na rozsahu hodnot parametrů. Počítá vzdálenost mezi objekty v systému souřadnic, jehož osy nemusí být na sebe kolmé. V praxi se používá pro zjištění polohy mezi skupinami objektů.“ [11] V diskriminační analýze je pak používána pro popis vzájemných vzdáleností centroidů skupin a vzdáleností objektů od centroidů skupin a následně pro výpočet posterior probabilities zařazení objektů do skupin. [11] [25]

Dopředná a zpětná eliminace proměnných z modelu je technika používaná při tvorbě regresních, diskriminačních a jiných modelů. Proměnné jsou do modelu postupně přidávány, popřípadě ubírány, podle jejich významu v modelu. V dopředné eliminaci, každá proměnná je individuálně zhodnocena co do významu pro diskriminaci skupin. Pro první krok musíme vybrat proměnnou s největším individuálním významem pro diskriminaci skupin. K vybrané proměnné jsou postupně přidávány další proměnné a je hodnocen význam dvojic proměnných pro diskriminaci skupin. V druhém kroku je do modelu přidána ta proměnná, která v kombinaci s již dříve vybranými proměnnými nejvíce přispívá k diskriminaci skupin. Postup je opakován až do vyčerpání všech proměnných nebo do situace, kdy přidání další proměnné již nevylepší diskriminační schopnosti modelu. Ve zpětné eliminaci se těmito pravidly řídíme přesně naopak. Model je nejdříve vypočítán a poté jsou odebírány jednotlivé proměnné a hodnocena jejich významnost pro skupinu. [25]

Konstrukce LDA se zakládá na několika předpokladech. Předně se při výpočtu LDA počítá, že soubor skupin dat je dichotomický. Skupiny tedy jsou samostatné a nepřekrývají se. Dalším je ohraničení modelu ze statistického hlediska. Nezávislé proměnné v modelu odpovídají proporcionálnímu rozdělení pravděpodobností a matice rozptylu jsou shodné mezi skupinami prosperujících popřípadě upadajících firem. V praxi

tyto ohraničení znamenají, že většina skupin dat by za běžných okolností neprošla do LDA, protože naplnit zmiňované předpoklady je složité. Na druhou stranu většina modelů založená na LDA tyto omezení vůbec neberou v úvahu a to vede ke zkreslení ve významnosti prováděných testů a odhadované míře chyb.[25]

Aposteriorní pravděpodobnost - v bayesovském přístupu je na začátku bankrotním a aktivním podnikům subjektivně přiřazena pravděpodobnost – tzv. apriorní pravděpodobnost (autorem volená na základě všech známých relevantních informací o podnicích a vzorku). Na základě posteriorní pravděpodobnosti jsou výsledky velmi velké (blíží se jedné) či velmi malé (blíží se nule). Pro snadnější přístup a využití apriorní pravděpodobnosti lze použít výpočetní programy.[9][11]

2.7. Modely podmíněné pravděpodobnosti

Modely podmíněné pravděpodobnosti jsou na rozdíl od LDA, daleko jednodušší na výpočet a řadí se mezi méně náročné statistické techniky. Základním kamenem těchto modelů je kombinace proměnných, které nejlépe rozlišují mezi skupinou bankrotních a aktivních podniků. Tyto modely umožňují odhadnout pravděpodobnost neúspěchu v závislosti na řadě charakteristik podniku pomocí nelineárního odhadu maximální pravděpodobnosti. Existují dva typy nejvíce rozšířené v akademické sféře. Prvním je logit analýza (dále jen LA), někdy také známá jako logit regrese. Druhou méně používanou je pak probit analýza. LA kombinuje několik parametrů do jediného skóre pravděpodobnosti pro celý podnik. Výsledkem je pak interval od $[0,1]$, kde skóre blíží se k číslu jedna, představuje velmi nezdravý podnik a u nuly je tomu naopak. Z klasifikačního pohledu je podstatou logit modelu rozdělit firmy na základě určitého logit a mezního skóre. Pokud se hranice logaritmu blíží nekonečnu, pak i výsledek v intervalu se bude blížit hodnotě jedna – bankrot. LA zakládá na dvou předpokladech: prvním je, aby závislé proměnné nepřekrývaly, byly bipolární se skupinami nespojitými a ztotožnitelné. Druhým předpokladem je při stanovení hraničních bodů, kdy by měli být uvažovány náklady na chyby I a II stupně. Nespornou výhodou LA je jednoduchá interpretace logit intervalu, který zároveň udává pravděpodobnost úpadku podniku. Výsledky jednotlivých ukazatelů je díky jednostranné závislosti možné interpretovat samostatně. Poslední výhodou je pak tvar logit funkce. Pokud posuzujeme dvě firmy, kdy jedna má podprůměrné zdraví a druhá dobré, je pak nemožné, pro podprůměrnou firmu

dosáhnout stejné křivky, jen pomocí zlepšení jediného ukazatele. Nevýhodou je naopak, pokud se v modelu objeví velká mnohostraná korelace a závislost mezi více faktory. Tento fakt je extrémním problémem, protože v podnikové teorii jsou poměrové ukazatele spolu úzce propojeny. [25]

2.8. Metoda klasifikačních stromů

Klasifikační nebo také rozhodovací stromy jsou souborem podmínkových pravidel, které rozdělují velkou heterogenní skupinu dat na menší, lépe homogenní soubor s ohledem na konkrétní hodnotu cílové proměnné. *„Pro stavbu rozhodovacích stromů se používají různé algoritmy, jako jsou například klasifikační a regresní stromy softwaru Microsoft (CART), kvadratická automatická detekce interakce (CHAID), nebo algoritmus redukce entropie (Ravi Kumar & Ravi 2007). Rozhodovací stromy jsou často používány pro klasifikační problémy, protože jejich pravidla jsou snadno pochopitelná a interpretovatelná (Cho, Hong, a Ha, 2010). Jejich výhodou je, že nemusí být tak robustní ohledně cyklických změn jako klasická lineární diskriminační analýza LDA.“* [25]

2.9. Problémy parametrických modelů

Přestože statistické metody jako LDA jsou velice rozšířené a setkáte se s nimi u většiny bankrotních modelů, existuje řada oblastí, které aplikaci těchto metod ztěžují. Je velmi nutné hledat a pochopit omezení těchto metod, aby se autoři v budoucnosti mohli vyhnout chybným modelům. Ve většině případů jde o následující problémy a omezení:

- Předpoklad bipolárně závislých proměnných,
- metodika výběru dat ze souboru,
- předpoklad stacionarity a nestability dat,
- výběr ročních finančních výkazů z účetní závěrky,
- časové dimenze.[8][25]

Bipolárně závislé proměnné

Klasické parametrické metody předpokládají, že závislé proměnné jsou dichotomické. V podstatě se jedná o nevyřešitelný problém. Metody potřebují jasně znát, jestli podnik je bankrotní nebo aktivní. To však není v praxi tak jednoduché. Firmy nebankrotují ze dne na den a proces úpadku společnosti je postupný a nenahodilý. Tudíž firmu, která trpí

finanční nemocí a je velmi náchylná na úpadek parametrická analýza určí jako aktivní. Toto tvrzení je sice pravda, ale až na rozdělení A ku B není praktické. V tvorbě modelu závisí nejen na vstupních proměnných, ale i na tom jak autor modelu definuje úpadek a bankrotní firmu. Pokud označí finančně nezdravou firmu za aktivní, pak i model se tímto postupem bude řídit v predikci bankrotu.

Metodika výběru dat ze souboru

Tento problém se týká výběru dat z celkového vzorku. Tedy určení tzv. reprezentativního vzorku dat, který tvoří určité procento jak bankrotních tak aktivních podniků. Tento vzorek by měl být však náhodný. Tato podmínka nicméně není u většiny modelů splněna, - je používáno tzv. „stavové rozdělení“. Použití funkcí náhodného čísla nebo náhodného výběru, je sice ve své podstatě taky nenáhodné, ale do značné míry postačující. Problém pokračuje i v určení velikosti vzorku, informačních dat ve vzorku a dalším skutečností. Například pokud náhodný výběr neobsahuje žádný bankrotní podnik. Jak již bylo zmíněno, většina autorů využívá stavové rozdělení z důvodu nízké četnosti krachujících podniků. Jde o rozdělení bankrotních podniků ve vzorovém souboru, podle toho kdy společnost zkrachovala. Tedy nedívá se na období krachu, ale jestli zkrachovala. Tento problém pokračuje s častou otázkou ohledně výběru dat u nekonzistentních dat společností. Jednoduše řečeno, u bankrotních firem existuje jen extrémě nízké procento kompletních dat, pro výpočet veškerých ukazatelů. [16]

Předpoklad stacionarity a nestability dat

Matematicko-statistické modely vyžadují, aby vstahy mezi proměnnými byly stabilní v čase. Dále předpoklad stacionarity znamená, že je nutné, aby vstahy mezi závislými proměnnými, byly po jistém časovém úseku totožné. V dnešní době je toto téměř nemožný požadavek, firmy se mění, adaptují a vyvíjí spolu s konkurencí, trhem a zákazníky. Výsledný model může během doby trpět ze špatných predikcí, tedy nemůže být použit v následovných časových obdobích, beze ztráty vypovídacích schopností.[25]

Výběr ročních finančních výkazů z účetní závěrky

Většina modelů využívá jako zdroje dat účetní závěrky, rozvahu, výkazy zisků a ztrát apod. Velkým problémem je, že v těchto dokumentech je popsána situace podniku, která nemusí zdaleka odpovídat realitě. Podniky mohou dělat úpravy svých dat a výkazů. Jakákoliv úprava může způsobit malé, ale důležité odchylky v tvorbě modelů a výběru

dat. U tvorby je tedy nutné počítat s tím, že ne všechny relevantní informace jsou pravdivé. [21]

Časové dimenze

Klasické statistické modely, jak již bylo zmíněno ignorují, že se během času společnosti mění. Fixní skóre, které je výstupem modelu je tedy nezávislé na čase. Autoři těchto modelů se vyhýbají otázce, jak zahrnout časovou dimenzi do svého výpočtu. Proto jejich výsledky většinou jsou pouhým shrnutím informací účetních výkazů a nedokáží posoudit jak bude firma vypadat v dalším období. Stručně řečeno klasické modely neberou v potaz čas a jejich výsledek je pouze odrazem nebo přirovnáním zda se firma podobá více bankrotní nebo aktivní šabloně modelu. [25]

2.10. Multivariate adaptive regression spline (MARS)

Je formou postupné lineární regrese představené roku 1991 J. Friedmanem. Představuje jednu z lehčích variant neparametrického přístupu tvorby modelů.

Multivariate - multivariabilní - Schopný generovat model založený na několika vstupních proměnných – multidimenzování.


Adaptive – adaptivní - generuje flexibilní modely, podobně jak dopředná analýza, každý další krok přizpůsobuje nastavení modelu.

Regression - regrese - odhad vztahů mezi nezávislými a závislými proměnnými.

Spline – spline - částečně definovaná funkce polynomu, která je spojitou křivkou (má derivace vyššího řádu) kde se polynomičné kusy pojí.

Knot – bod - bod, ve kterém jsou dva polynomičné kusy pojí dohromady.

Obrázek 2: MARS regrese



Zdroj: Literatura - MARS [4]


2.11. Neuronové sítě

Neuronové sítě (NN) jsou pravděpodobně nejrozšířenější neparametrickou metodou používanou v rámci inteligentních programovacích technik (Demyanyk & Hasan, 2010). Principem NN je, napodobit biologické neuronové sítě lidského nervového systému pomocí matematického algoritmu. Tato nejnovější technologie nabízí dvě zajímavé výhody ve srovnání s klasickými statistickými metodami. První z nich je, že neuronové sítě stejně jako ne-parametrické modely, se nespolehlivě na specifické předpoklady, jako je distribuce prediktorů nebo vlastnosti dat. Díky tomu jsou spolehlivější než modely, u kterých se musí předpoklady dodržet z důvodů podmínek výpočtu modelu. (Bardos, 2001). Další výhodou je spoléhání se na nelineární přístupy, které nabízí rozšířené možnosti testování složitých souborů dat. Nevýhodou je, že modely NN mohou být více ovlivňovány časovými nebo cyklickými změnami v ekonomice, než je tomu u klasických statistických metod. Neuronové sítě se také obtížněji interpretují.[25]

Typy neuronových sítí:

- Víceparametrické NN
- Pravděpodobnostní NN
- Auto-asociativní NN
- Sebeorganizující se mapy
- Kaskádní korelace

Obrázek 3: Příklad neuronové sítě



Zdroj: Vlastní úprava na základě literatury [7]

2.12. Hybridní modely

Hybridním modelem jsou obecně považovány kombinace určitých klasických modelů a neuronových sítí. „Lee a kol. (1996) testoval kombinace modelů jako MDA, ID3, SOM a BPNN. Srovnával prediktivní schopnosti u korejských firem a došel k závěru, že SOM společně s NN dosahovali lepších výsledků. O jedenáct let později pak Lee testoval nový hybridní model. Studie Lee, a kol. (2005) porovnávala kontrolované (supervised) a nekontrolované (unsupervised) NN za použití jejich reprezentativních typů – BPNN za kontrolované a Kohonenova SOM jako reprezentativní typ pro nekontrolované NN.“[25] Možnostmi sestavení hybridního modelu se zabývali například Back, Laitinen a Sere (1996). Porovnáním přesnosti modelu kombinující logit model s metodou MDA a neuronovou sítí, dosáhli nejvyšší přesnosti modelu. [12]

„Chen a Hsiao (2008) užili genetické algoritmy (GA) ve spojení se support vector machine (SVM). Za zmínku stojí, že tito autoři rozšířili své zkoumání i o možnosti využití ukazatelů hodnotících intelektuální kapitál. Jejich výsledný model obsahoval pět finančních ukazatelů a jeden ukazatel hodnotící intelektuální kapitál²⁰. Výsledná celková přesnost modelu činila 95%. Pro srovnání Altmanův model z roku 1968, založený na MDA, dosáhl přesnosti 92%.

Jiný přístup k sestavení hybridního modelu, zvolil Lin (2009). K nalezení proměnných modelu využil logistickou regresi a ke klasifikaci umělou neuronovou sítí. Jako alternativu

logistické regrese zkoumal možnosti využití tzv. Altmanovy logaritmické logistické regrese (viz Altman, 2006) a zjistil, že tato metoda nemusí vždy vést k lepším výsledkům oproti klasické variantě logistické regrese.“ [12]

2.13. Určení šedé zóny

Šedá zóna, jak již napovídá název, je oblast dat, které bankrotní model nedokáže určit. Aktivní a bankrotní podniky, které se výsledkově překrývají mohou být označeny za členy šedé zóny. Tato možnost výrazně zvyšuje relativní přesnost modelu. Model jako takový udělá stejnou chybu – např. označí aktivní podniky jako bankrotní od určité hodnoty modelu, ale pokud je tato hodnota v interval zóny, pak je výsledek označen za tzv. nemožný určení finančního zdraví podniku. Jak již bylo zmíněno, přestože šedá zóna dokáže zvýšit přesnost modelu, zároveň se podílí na snížení počtu podniků pro které lze tento model aplikovat.[13]

Obrázek 4: Koncept šedé zóny



Zdroj: Vlastní zpracování

3. POPIS TESTOVANÝCH MODELŮ

V této kapitole je zaměřena na úvod do teorie bankrotu, bankrotních modelů, jejich vývoje, popisem nejpoužívanějších modelů, jejich charakteristikou a přesností.

Krach podniku je úzce spojený s úvěrovým rizikem. Toto riziko na sebe bere jakýkoliv podnik při vstupu do dodavatelsko odběratelských vztahů. Riziko, že dodavatel či odběratel nedostojí svým závazkům a nebude schopen splatit svůj dluh podniku, je v dnešní době běžnou součástí podnikání. Firmy si sice tvoří rezervy a snaží se sjednat, co nejvíce dodavatelů a odběratelů, ale díky propojenosti v logistické sféře, se může neblahé finanční zdraví přenášet z jednoho podniku na druhý jako nemoc. Bankrot, krach firmy z důvodů neschopnosti dodržet svým závazkům, může být v krajních případech vyvolán právě touto platební neochotou.

Příčin bankrotu je hned několik. První a nejstarší příčinou je špatné vedení firmy. Tímto není myšleno pouze finanční řízení, ale jde o celý soubor vedení, počínaje konkurenčními střety, marketingem, logistickou efektivitou, hospodárností až po vedení zaměstnanců. Zanedbávání jakéhokoliv z těchto faktorů může způsobit obrovské ztráty nebo krach. Některé faktory však podnik nemůže ovlivnit. Jde o přírodní a klimatické pohromy, ale také vedení firem napojených na podnik nebo změnu preferencí zákazníka. I když bude firma dodržovat veškerá pravidla, generovat zisk, mít správné vedení a výborné vstahy, inovovat, ztráta hlavních partnerů a jejich platební neschopnost může podnik velmi rychle oslabit. Je důležité zmínit, že bankrot nemá v České republice právní rámec. Je to pojem převzatý z italského slova „*banca rotta*“ v doslovném překladu zlomená lavice, který pak převzal jazyk anglický a vytvořil slovo „*bankruptcy*“ v českém překladu bankrot. V Spojených státech amerických lze najít v zákoně „National Bankruptcy Act“ z roku 1898 v příloze pro „Federal Bankruptcy Act“ z roku 1938 přímé vysvětlení tohoto slova. Jde o legalní status, který vyhlásí fyzická nebo právnická osoba pokud nemá a nemůže splatit dlužnou částku věřiteli. Ve většině případů je nutno požádat soudní orgán, aby bankrot schválil. Jde o způsob, jak dát dlužníkovi možnost nového začátku a možnosti splácet svoje dluhy postupně.

Oddlužení a úpadek

Oddlužení v České republice také nazývané jako tzv. osobní bankrot, je způsob řešení úpadku, který ve zvýšené míře zohledňuje aspekty sociální před ekonomickými. Má umožnit dlužníkovi začít od nového začátku a motivovat ho k aktivnímu splácení dluhu

z minulé ekonomické činnosti. Liší se výší do které dlužník splácí podle typů věřitelů, na nezajištěné 30 % a zajištěné 100 %. Druhým benefitem oddlužení je fakt, že umožňuje snížit náklady veřejných rozpočtů na sanaci těchto dlužníků. Oddlužení se většinou používá u fyzických osob.

Úpadek je daleko více podobný bankrotu z pohledu podniku. Insolvenční zákon rozlišuje dvě základní formy úpadku, úpadky z důvodů platební neschopnosti a předlužení. Úpadek z důvodů platební neschopnosti představuje situaci, kdy má dlužník více věřitelů, má nesplacené závazky déle jak 30 dnů po splatnosti a není schopen tyto závazky plnit. Jde o klasický problém dlužníka, který není schopen uspokojit splacení peněžních pohledávek. Úpadek ve formě předlužení nastává, má-li dlužník více věřitelů a zároveň souhrn jeho závazků převyšuje hodnotu jeho majetku. Pokud by vše ihned prodal tak stejně nebude schopen uspokojit cizí pohledávky.

3.1. Historie vývoje modelů bankrotu

První zmínky o analýze firemního bankrotu můžeme najít již před dvěmi stoletími. Modely v této době sice ještě neexistovali, ale finanční problémy podniku byly hodnoceny na základě velmi subjektivních informací. Některými ukazateli kterými se vědecká společnost zabývala byly: schopnosti a dovednosti vrcholového managementu, jeho velké finanční zapojení v základním kapitálu firmy – z důvodů bezpečnosti a motivace, vývoj odvětví ve kterém podnik působí a posledním ukazatel byla skutečnost zda si firma vytváří finanční rezervy pro případ nenadálých událostí. Některé z těchto ukazatelů se v modelech bankrotu, popřípadě finančním řízení podniku používají i dnes. Začátek 20. století je spojován s používáním ukazatelů generovaných z finančního účetnictví podniku. Čerpání informací a výpočet ukazatelů ze základních účetních dokumentů jako jsou rozvaha, výkaz zisku a ztráty nebo výkaz peněžních toků, nahradil léta zaběhlé přístupy hodnocení podniku. Prvním průkopníkem v používání finančních ukazatelů v modelech byl W. Beaver v roce 1966. Jeho studie finančního zdraví podniku pomocí poměrových ukazatelů je průlomová. Beaver studoval jak data z účetních výkazů dokáží predikovat budoucí vývoj podniku. Porovnáváním dat z aktivních a bankrotních podniků pak přišel na některé souvislosti které dokázali s určitou přesností predikovat bankrot firmy až pět let dopředu. O dva roky později, E. Altman publikoval první vícerozměrnou studii známou jako „Z-skóre“, která je založená na diskriminační analýze.

Jednalo se o první využití více poměrových ukazatelů v jediném výpočtu. Model se choval velmi dobře v odvětví průmyslových podniků a s velkou přesností dokázal rozlišit nebo určit budoucí bankrotní podnik. Meyer & Pifer v roce 1970 využili lineární model pravděpodobnosti (LPM). Jedná se o zvláštní případ aplikace regrese pomocí metody nejmenších čtverců na vytvoření závislých proměnných pro bankovní konkurzní predikci. Vývoj modelů a přístupů k jejich vytváření pokračoval s časem a vědci se soustředili na zlepšování stávajících modelů a kombinací jednotlivých analýz na podobná data v jistých časových úsecích. V sedmdesátých letech pak R. Edmister po sérii testů a modelování přišel s tím, že používáním diskriminační analýzy lze dosáhnout daleko lepších výsledků a přesnosti modelu. V roce 1972, Edmister začal testovat celou řadu metod finanční analýzy, které by mohly pomoci předpovědět selhání malých a středních průmyslových podniků. Výsledky byly rozporuplné. Ne všechny způsoby a poměry se daly použít jako predikátory selhání, ale potvrdilo se, že některé poměrové proměnné by mohly být použity k predikci selhání malých obchodních společností. Dalším pozitivem jeho testování bylo doporučení používat účetní závěrku z více po sobě následujících období s minimem ve tři let pro predikci bankrotu a výpočet modelů. V roce 1977, E. Altman publikoval vylepšené Z-skóre, jménem "*Zeta model*". Model srovnával lineární a kvadratickou diskriminační analýzu, jejich použití v rovnici Z skóre, testování na stejných datech a eliminaci chyb prvního a druhého stupně. Altman tím získal velmi kvalitní výsledky s přesností klasifikace nad 95 % pro rok a nad 70 % pro pět let před bankrotem. M. Zmijewski roku 1984 usoudil, že odhadovat modely pomocí závislých a nenáhodných vzorků může vést ke katastrofálnímu odklonění, pokud se nevyberou vhodné techniky odhadu. Konkrétně uvedl dvě předpojatosti odhadu. První vyplývající z nadměrného použití problémových firem a druhá z použití pouze úplných údajů. Zmijewski také využil další zajímavou formu logistické regrese, „probit model“ závisející na probit analýze, aby podpořil svá zjištění. V roce 1993 E. Altman přizpůsobil svoje "Z-skóre" pro aplikování v soukromém sektoru. Tento nejnovější model se liší od původního "Z-skóre" nahrazením účetní hodnoty vlastního kapitálu za tržní hodnotu a přehodnocením všech koeficientů modelu. Altman a kolektiv pak o dva roky později uplatnili další adaptaci původního "Z-skóre" na firmy, které nejsou výrobci nebo operují na rozvíjejících se trzích. V tomto nejnovějším modelu, znovu přehodnotili koeficienty modelu a rozhodli se snížit poměr obrátu aktiv, aby se minimalizoval potenciální efekt

průmyslu oproti původnímu modelu "Z-skóre". V České republice zastupují bankrotní modely hlavně indexy IN. Manželé Inka a Ivan Neumaierovi v roce 1995 vytvořili první model, který byl čistě aplikován na České podmínky a podniky. IN neboli index důvěryhodnosti byl sestaven na základě souboru 100 českých podniků a jejich testování pomocí vybraných statisticko-matematických metod. Tento model na rozdíl od mnoha zahraničních přesně hodnotí průmyslové podniky v českých podmínkách. Tedy ve specifikacím účetních výkazů, ekonomické situace a procentu zastoupení kapitálového trhu. Jako většina modelů jsou indexy důvěryhodnosti tvořeni poměrovými ukazateli z oblasti rentability, aktivity, likvidity a zadlužení. Během let 1995 až 2005 manželé Neumaierovi vytvořili další varianty těchto indexů.[1][2][3][18][22][23]

3.2. Modely bankrotu

Bankrotní modely jsou důležitým pomocníkem jak pro firmy tak zejména pro bankovní sektor. Kdykoliv má banka schválit klientovi – firmě úvěr, zkoumá zda je tento subjekt finančně zdravý a schopen splácet vypůjčenou částku. Na základě kladných výsledků z modelů pak finanční instituce klientovi půjčí. Banky tím však na sebe berou velké riziko, to je sice kompenzováno úrokem, ale mnohem důležitější je dobře klienta ohodnotit a vyvarovat se ztrátě. K tomu slouží bonitní, bankrotní a bonitně bankrotní modely.(1)

Tato část práce popisuje tyto modely:

- Beaverova analýza
- Altmanovo Z skóre
- Tafflerův bankrotní model
- Zmijewski model
- Altman Sabato model
- Indexy IN

3.3. Beaverova analýza

V roce 1966 W. Beaver testoval možnosti finančních ukazatelů zachytit riziko spojené se zhoršujícím se finančním zdravím firmy. Pro svou analýzu využil poměrové finanční ukazatele, které díky matematické logice mají vyšší výpovědní i porovnávací schopnost. Výběr ukazatelů záležel čistě na frekvenci používání ve finančních analýzách minulých

let. Identifikace finančního zdraví firmy a jeho stavu poté nazval analýzou profilu, z překladu „*profil analysis*”. Podstatou jeho analýzy bylo porovnávání výsledků poměrových ukazatelů s průměrem daného ukazatele pro velký vzorek firem. Pokud se podnik značně vymykal průměru a měl tendence směřovat k nižší výsledkům, pak Beaver označil tento podnik za bankrotní. Z testovaných poměrových ukazatelů vybral Beaver pětici s největší výpovědní schopností. Výpovědní schopností se rozumí váha se kterou daný ukazatel dokáže předurčit bankrot. Čím větší je váha ukazatele, tím větší četnost bankrotních nebo aktivních podniků byla okolo určitého číselného intervalu. Za ukazatel s nejvyšší výpovědní schopností pro určení blízkého se bankrotu označil poměr cash flow ku celkovým cizím zdrojům podniku. Dalšími ukazateli u kterých se Beaver zmínil ve své analýze jsou podíl přidané hodnoty ku celkovým aktivům, bankovní úvěry ku cizím zdrojům, provozní kapitál ku celkovým aktivům a obdobně podíl vlastního kapitálu ku celkovým aktivům. Velkou nevýhodou Beaverova přístupu je fakt, že se nejedná o komplexní model, jehož výsledkem by bylo číslo nebo interval, který by jasně určil v jaké je podnik situaci. Této průkopnické analýze však patří velký dík, hlavně díky profilování a inspirování pro ostatní autory.[5][22][25]

3.4. Altmanovo Z – skóre

V roce 1969 sestavil Edward I. Altman první ze svých modelů nazvaných Z skóre. Tyto modely založené většinou na diskriminační analýze jsou jednou z nejpoužívanějších bonitně bankrotních metod na světě. Testovací data tvořil vzorek 66 firem, rozdělený na poloviny dle finančního zdraví na bankrotní a aktivní. Bankrotní skupinu tvořili podniky řazené do bankrotní petice (*bankruptcy petition*) v „National Bankruptcy Act“ v letech od 1946 do 1965. Podobně nebankrotní skupinu poskládal Altman ze společností, velice podobných majetkové a velikostní struktuře skupiny první. Povolený interval aktiv činil 1 až 25 milionů dolarů. Druhým krokem, po rozdělení bankrotních a aktivních skupin, bylo vybrat potřebné informace z rozvahy a výkazu zisku a ztrát. Pro první výpočet Altman určil 22 ukazatelů, které podle něj mají velkou výpovědní schopnost o zdraví podniku. Ukazatele posléze rozdělil do 5 standardních poměrových kategorií, ukazatele likvidity, zadluženosti, rentability, solventnosti a řízení aktiv. Volba ukazatelů spočívala hlavně na základě jejich popularity mezi akademickou obcí. Z původních 22 ukazatelů jich nakonec bylo vybráno 5, které dokázali velice schopně předpovědět bankrot podniku, ale

zároveň určit aktivní firmu, pokud byla v pořádku. Pro dosažení konečného rozložení ukazatelů Altman použil následující postup. Porovnal statistický význam různých alternativních funkcí, včetně určení relativního příspěvku každého nezávislého ukazatele. Ukazatel s největším přírůstkem pak pokračoval dále do užšího výběru. Tento výběr byl poté podroben korelační analýze, která ocenila a vyloučila vstahy nejvíce spolu podobných ukazatelů. Následovalo pozorování předvídatelné přesnosti různých profilů a celkový odhad diskriminační analýzy. Výsledná diskriminační funkce a její úprava má tvar:

$$Z_1 = 0,012X_1 + 0,014X_2 + 0,033X_3 + 0,006X_4 + 0,999X_5$$

$$Z_2 = 1,2X_1 + 1,4X_2 + 3,3X_3 + 0,6X_4 + 1,0X_5$$

Nahoře lze najít jak původní Z skóre, tak postupem času pozměněné Z skóre. Původní skóre je nutno přepočítat na procentní hodnoty. Alespoň ukazatele X_1 až X_4 , hodnota ukazatele X_5 se nikdy neuvádí v procentech, ale počítá se rovnou s celým čísle a totéž platí i pro dosazení dat do vzorce.

Tabulka 1: Přesnost Altmanova Z skóre

Roky před bankrotem	První vzor	(+25 firem)	1969-1975	1997-1999
1	94%	96%	82%	94%
2	72%	80%	68%	74%

Zdroj: Vlastní úprava na základě literatury Altman [3]

Přesnosti Altmanových modelů zobrazuje tab. č. 1. Rok pře bankrotem se modelům podařilo určit v průměru přes 90 % podniků což je více jak pozbuující. Nejaktuálnější modely jsou zmíněny v práci jako samostatná kapitola.

$$Z_1 = 0,012X_1 + 0,014X_2 + 0,033X_3 + 0,006X_4 + 0,999X_5$$

Poměrové ukazatele a váhy v Altmanově modelu:

- X_1 - Pracovní kapitál / Celková aktiva
- X_2 - Nerozdělený zisk / Celková aktiva
- X_3 - EBIT / Celková aktiva
- X_4 - Tržní kapitalizace / Cizí kapitál
- X_5 - Tržby / Celková aktiva
- X_6 - Závazky po splatnosti / Tržby³

³ Platí pouze pro Altmanův model pro Českou republiku

Celková aktiva jsou soubor veškerého majetku firmy vyjádřený v peněžních jednotkách. Rozdělení v rozvaze je na dlouhodobá a oběžná. Dlouhodobá aktiva tvoří majetek, který je v podniku déle než jeden rok. Dělí se na stálá aktiva - majetek hmotný, nehmotný a finanční. Na rozdíl od ostatních položek majetek tohoto typu je většinou financován dlouhodobými zdroji a pokud by v časové řadě hodnota tohoto majetku klesala, lze tento krok považovat za jeden z ukazatelů bankrotu. Firmy se neradi zbavují dlouhodobého majetku z důvodů jeho nízké likvidity a relativní důležitosti v podnikání. Druhou součástí celkových aktiv je oběžný majetek – často též nazývaný jako oběžná nebo krátkodobá aktiva. Jde o položky aktiv které jsou v podniku méně než jeden rok, tvoří je zásoby, hotovostní peníze a pohledávky.

Pracovní kapitál tvoří rozdíl mezi krátkodobým majetkem a krátkodobými závazky. Z tohoto výpočtu vyplývá, že pracovní kapitál je část krátkodobých aktiv financovaná dlouhodobými zdroji. Pro podnik je důležitý z hlediska fungování, protože čím menší je pracovní kapitál, tím hůře se firmě povede bude-li muset splatit všechny svoje závazky ve velmi krátkém období. Tento ukazatel představuje míru připravenosti a kvality v době nedůvěry v dodavatelsko-odběratelských vztazích. V běžném období je pracovní kapitál používám jako prostředek pro realizaci podnikových záměrů a pouze v krizi slouží jako tzv. „finanční polštář“. V podnikové ekonomii se lze setkat s více faktory které určují velikost pracovního kapitálu, popřípadě jeho bezpečností velikosti. Faktory jako jsou doba obratu zásob, pohledávek a závazků. V altmanově modelu pak tvoří spolu s celkovými aktivy první z poměrových ukazatelů. Jde o vyjádření flexibility podniku na celkovém majetku.

Celkové tržby jsou tvořeny peněžní částkou získanou z prodeje výrobků a poskytování služeb, penězi generovanými z prodeje majetku, cenných papírů a podílů. Jsou jednou z nejdůležitějších finančních složek podniku a představují hlavní složku výnosů. Tržby za prodej zboží se určí jako násobek počtu prodaných produktů a jejich individuálních cen. Podnik může způsobit růst svých tržeb pomocí různých faktorů. Jde hlavně o zvyšování kvality svých výrobků a služeb. Zavádění nových produktů a inovací na trh. Účinnou marketingovou strategií a v poslední řadě zvyšování cen produktů. U modelu Z skóre pak celková aktivita dělí tržby. Důvodem je nalezení příspěvku jednotlivých složek majetku na přidané hodnotě. Je tedy ukazatelem výkonnosti.[15]

Nerozdělený zisk je specifická část zisku, která je oddělená od veškerých odečitatelných položek a nerozděluje se mezi majitele společnosti, ale slouží jako zdroj financování dalšího podnikání. V rozvaze jej lze najít v pasivech ve složce vlastní kapitál. Nerozdělený zisk je součástí kapitálových a rezervních fondů. Společnosti působící na trhu déle mají obrovský nerozdělený zisk a naopak jakákoliv malá i velká firma, jenž byla založena nedávno, nemá šanci na veliký nerozdělený zisk. Jde totiž o kumulaci jednotlivých zisků z minulých let. S rostoucím časem a neinvestováním společnosti, tato složka výrazně roste. Nerozděleným ziskem lze financovat celková aktiva společnosti. Tato skutečnost dává firmě, která již má úvěry a nedostala by dobrý úrok, možnosti, jak financovat svoje investice bez navýšení závazků a z nich plynoucích úroků.

EBIT z anglického „*Earnings Before Interest and Taxes*“ je výsledek hospodaření, zisk, před odečtením úroků a daní. Ve výkazu zisku a ztrát je brán jako hospodářský výsledek z běžné činnosti. Tedy vše co společnost prodá ochuzené o celkové náklady a odpisy. EBIT se skládá z výsledků hospodaření z provozní a finanční činnosti a dlužných úroků. EBIT je jedním z ukazatelů rentability v podnikové ekonomii. Používá se hlavně pro výpočty rentability aktiv a pro výpočet čistého zisku. Slouží také jako porovnávání podniků v rámci mezinárodního prostředí protože nezahrnuje míru zdanění zisku, která se může lišit mezi jednotlivými státy.[15]

Cizí zdroje jsou v rozvaze začleněny v pasivech. Vyjadřují veškeré dluhy společnosti. Představují závazky - dluhy, které společnost dosud neuhradila svým věřitelům. Cizí zdroje se skládají v rozvaze z dlouhodobých a krátkodobých závazků a bankovní úvěrů a rezerv. Altman doporučuje do modelu Z-Score dosazovat cizí zdroje zmenšené o rezervy a to z prostého důvodu: bez rezerv je jasné vidět po výpočtu zda podnik má na úhradu svých závazků vzhledem ke své provozní činnosti.

Tržní kapitalizace neboli „vlastní kapitál“ tvoří základní kámen podniku. Jde o kapitál, který patří majitelům společnosti. Z hlediska využití jde o primární zdroj financování dlouhodobého majetku společnosti. V rozvaze patří ke složce pasiv a je opakem cizích zdrojů. Při neschopnosti uhradit závazky podniku je vlastní kapitál využit na splácení dluhů. Podíl na celkovém kapitálu je ukazatelem finanční jistoty společnosti. Vlastní kapitál se mění podle výsledků hospodaření z důvodů, že v rozvaze obsahuje i nerozdělený zisk a zisk z minulých let.

Hodnocení podniků v Altmanově modelu

Hranice, které dělí bankrotní a aktivní podniky jsou uvedeny následovně po tomto textu. Podle výsledku Z-Score modelu je společnost klasifikována do jednoho ze tří pásem, do aktivní zóny, bankrotní zóny a nebo šedé zóny. Toto rozdělení ohraničují tyto intervaly:

- $Z > 2,99$ → Aktivní zóna – společnost je finančně stabilní
- $Z = (1,81 ; 2,98)$ → Šedá zóna – společnost je nestabilní
- $Z < 1,80$ → Bankrotní zóna – společnost má velké finanční potíže

První meze rozdělení je konstanta 1,80, která tvoří hranici mezi bankrotní a šedou zónou. Pokud se bude společnost nacházet v intervalu menší než toto číslo, tedy celkový model ji takto posoudí, lze očekávat velké finanční a výkonové potíže. Bankrotní zóna není sice bezchybná a predikování bankrotu již vůbec ne, ale jako dostatečný ukazatel pro rozhodování a řízení zcela postačí. Výsledek modelu pro společnost, který je větší než číslo 1,80 znamená zařazení do šedé – neboli neurčité zóny. V tomto intervalu model sice není schopen určit zda je podnik finančně zdravý. Z výsledků se dá poznat, ke které skupině podnik inklinuje a pro vlastníky naznačuje, že by mohlo být něco lépe. Aktivní a zdravé podniky se vyskytují v zóně ohraničené z dola hodnotou 2,99. Tyto podniky jsou klasifikovány jako vhodné pro investování. [3]

Druhy Altmanova Z skóre:

- Z-Score model pro akciové společnosti
- Z-Score model pro neakciové společnosti
- Z-Score pro ekonomiku ČR
- Z-Score model pro nevýrobní společnosti
- Obecný tvar Z-Score a ukazatele [22]

V českém průmyslu má platební neschopnost a úpadek velký význam. Z-Score model byl tedy doplněn o další ukazatel X_6 . Velkou nevýhodou modelu je malý počet podniků, které zbankrotovaly. Tímto problémem trpí většina modelů v našich podmínkách. Neexistuje tedy dostatečně velký vzorek dat z podniků, které by mohli být testovány a upraveny přesně na míru.

Úprava Altmanova modelu pro použití v Českých podmínkách:

$Z_{cz} = 1,2X_1 + 1,4X_2 + 3,3X_3 + 0,6X_4 + 1,0X_5 - 1,0X_6$
--

kde X_6 - Závazky po splatnosti / Tržby

Závazky po splatnosti jsou částí celkových závazků a tím pádem i cizích zdrojů podniku. Čím vyšší je jejich procento tím více je podnik náchylný k úpadku. Dle finančního zdraví by vůbec tyto závazky neměli vznikat, jinak bude firma nejen špatně hodnocena v dodavatelsko odběratelských vztazích, ale i na pozici finančního a kapitálového trhu. Z pohledu modelu je důležité určit jejich podíl na tržbách. Čím jsou závazky větší, tím více bude podnik padat do bankrotní zóny. Tento fakt je i jedním z důvodů proč je ve Altmanově vzorci znaménko mínus při X_6 . [1][3]

3.5. Tafflerův bankrotní model

Tafflerův model je další z bankrotních modelů, který sleduje riziko bankrotu společnosti. Poprvé byl představen v roce 1977 na základě dat z podniků od roku 1969 až 1975. Z analyzovaných dat bylo vybráno 90 ukazatelů ze kterých po vytvoření modelu zůstaly pouze čtyři. Autor vytvořil základní a modifikovaný tvar, ale obě verze využívají čtyři poměrové ukazatele. Velkou zajímavostí celého modelu je, že model nepoužívá žádný ukazatel rentability.[22][23]

$$Z_t = 0,53 \cdot \text{EBT}/\text{KZ} + 0,13 \cdot \text{OA}/\text{CZ} + 0,18 \cdot \text{KZ}/\text{CA} + 0,16 \cdot \text{TR}/\text{CA}$$

kde EBT / KZ - představuje poměr zisku před zdaněním oproti krátkodobým závazkům. Funkce tohoto ukazatele je především pro určení, zda je podnik schopen splácet své závazky při dosahovaném zisku.

OA / CZ - je podílem oběžných aktiv proti veškerým cizím zdrojům podniku. Poměr představuje míru zásob a peněz oproti veškerým závazkům, které podnik dluží svým věřitelům a dodavatelům.

TR / CA - poměr celkových tržeb na celkových aktivech, představuje klasický ukazatel rychlosti obratu aktiv.

KZ / CA - dělení krátkodobých závazků vůči celkovým aktivům. Ukazatel vyjadřuje zadlužení společnosti v jednotkách majetku (vyjádřených samozřejmě v penězích).

Hranice pro jednotlivé zóny, jak bankrotní, tak aktivní se mění s každým modelem. Pro tento index autoři vybrali:

$Z_t > 0,3$ → podnik je málo náchylný k bankrotu

$Z_t < 0,2$ → u podniku je vyšší pravděpodobnost úpadku

U staršího modelu se můžeme setkat stále s názorem, že aktivní a bankrotní zónu dělí číslo nula.

3.6. Zmijewski model

Zmijewski použil metodu probit k předpovědi bankrotu, model je od té doby nazýván "Zmijewski Score". Metoda probit představuje inverzní distribuční funkci normálního rozdělení. Výsledek probitové regrese je podobný výsledku logitové regrese mezi 1 a 0. Většina předpovědních modelů bankrotů bere nezávislé proměnné založené na teorii a vybírá takové s nejvíce prognostickým výkonem. Zmijewski však založil svůj výběr nezávislých proměnných čistě na tom, jak dobře proměnné předpovídaly v předchozích modelech. Přesnost Zmijewského skóre byl v době jeho vzniku kolem 95 % pro bankrotní podniky a uctihodných 99,39 % pro nebankrotní. Celkový vzorek tvořilo 800 nebankrotních a 40 bankrotních podniků.[22]

$$Z_s = -4.336 - 4.513 * (EAT/CA) + 5.679 * (CZ/CA) + 0.004 * (OA/KZ)$$

kde EAT / CA - je poměrem zisku odděleného úrokových nákladů a daní, podělená celkovými aktivy. Tento vzorec je netradičním vyjádřením rentability aktiv.

CZ / CA – vyjadřuje vztah cizích zdrojů vůči aktivům. Jde o ukazatel podílu veškerých nevlastních peněz a závazků proti celkovému majetku podniku.

OA / KZ – je podílem oběžných aktiv proti krátkodobým cizím zdrojům podniku. Poměr představuje míru zásob a peněz oproti závazkům, které podnik dluží svým věřitelům a dodavatelům v době jednoho roku.

3.7. Altman Sabato model

V roce 2007 Edward Altman a Gabriele Sabato navrhli model pro trh v USA. Důležitým faktorem použitým v tomto modelu bylo logaritmování veškerých ukazatelů kvůli zvýšení přesnosti modelu. To se ukázalo jako správná cesta a model inspirovaný právě Altmanovým Z skóre, je jedním z nej přesnějších modelů bankrotu. Druhým důvodem úspěchu tohoto modelu je zaměření ukazatelů na Basel II kapitálové požadavky. Díky tomuto kroku je model nejen přesný ale i po účetní stránce snadno vypočitatelný.[2]

Tabulka 2: Výběr proměnných modelu

Posuzované proměnné	Vybrané proměnné	Proměnné v modelu	Účetní kategorie
Krátkodobý dluh / Vlastní kapitál Vlastní kapitál / Celkové závazky Závazky / Celková aktiva	Krátkodobý dluh / Vlastní kapitál	Krátkodobý dluh / Vlastní kapitál	Pákový efekt
Peníze / Celková aktiva Pracovní kapitál / Celková aktiva Peníze / Tržby Nehmotná aktiva / Celková aktiva	Peníze / Celková aktiva Pracovní kapitál / Celková aktiva	Peníze / Celková aktiva	Likvidita
EBIT / Tržby EBITDA / Celková aktiva EAT / Celková aktiva Nerozdělený zisk / Celková aktiva EAT / Tržby	EBITDA / Celková aktiva Nerozdělený zisk / Celková aktiva	EBITDA / Celková aktiva	Rentabilita
EBITDA / Nákladové úroky EBIT / Nákladové úroky	EBITDA / Nákladové úroky EBIT / Nákladové úroky	Nerozdělený zisk / Celková aktiva	Pokrytí dluhu
Tržby / Celková aktiva Závazky / Tržby Pohledávky / Závazky	Tržby / Celková aktiva Pohledávky / Závazky	EBITDA / Nákladové úroky	Aktivita

Zdroj: Vlastní úprava na základě literatury Altman Sabato [2]

Jako Altmanovo Z skóre i tento model byl navržen tak, aby obsahoval ukazatele ze všech oblastí finanční analýzy, tedy oblasti likvidity, rentability, aktivity, dluhového krytí, finanční páky. Výsledný vzorec pro nelogaritmický model je následující. Využitím logistické regrese přišli autoři na konečný upravující model s větší přesností k sumě 4,28. Hranice jednotlivých zón je pak číslo 4,28. Jde o to, jestli se firma přehoupne přes tuto hranici. 4,28 je předpokládaná pravděpodobnost že firma zůstane aktivní. Pokud však nedosáhne na tuto hranici, pak firmu můžeme označit za bankrotní.(3)

$$Z_{unlog} = + 4,28 + 0,18 * EBITDA/CA - 0,01 * KZ/VK + 0,08 * NZ/CA + 0,02 * OA(p)/CA + 0,19 * EBIT/NU$$

kde EBITDA/CA - ukazatelem rentability je dělení celkového zisku (zisk s daněmi, úroky a amortizací) celkovými aktivy.

KZ / VK - podíl krátkodobých závazků oproti vlastnímu kapitálu vyjadřuje pákový efekt

NZ / CA – nerozdělený zisk dělený celkovými aktivy je ukazatelem pokrytí dluhu. Čím více nerozděleného zisku společnost disponuje, tím více je krytá v případě předvídatelných i nepředvídatelných provozních situací.

OA(p)⁴ / CA – naznačuje podíl hotovostních a bezhotovostních peněz na účtech k celkovým aktivům společnosti. Ukazatel likvidity vyjadřuje jak rychle podnik dokáže měnit svůj majetek na peníze.

EBIT / NU - je poměr zisku před zdaněním po odečtení nákladových úroků, dělený právě nákladovými úroky. Zajišťuje tedy znalost úrokového krytí a možnosti, kolik nových úvěrů by mohl ještě zisk podniku pokrýt.

$$Z_{\log} = +53,48 + 4,09 * \ln(1 - (EBITDA/CA)) - 1,13 * \ln(KZ/VK) + 4,32 * (-\ln(1 - (ZZ/CA))) + 1,84 * \ln(OA(p)/CA) + 1,97 * \ln(EBIT/NU)$$

kde jsou všechny ukazatelé naprosto stejné, kromě jejich vah a logaritmování. Tento model je daleko přesnější než jeho nezlogaritmovaný protějšek. Oproti 75 % přesnosti při nelogaritmovaném modelu se přesnost zvýšila o celých 12 % až na hranici 87 %. Tento fakt ukazuje, že modely, které vycházejí nad hranicí 60 % mohou být díky logaritmování daleko přesnější. Důvodem je právě charakteristika logaritmu. Ten zapříčiní, že obrovské odchylky dat jsou najednou umocněny na velmi malá čísla a tudíž i rozdíly se dostávají do řádu desetiných čísel. Použitím logistické regrese se autoři dobádali nejen změněných vah, ale i výsledná hranice se posunula na číslo 53,48. [2]

3.8. Indexy IN

Na našem území se tak jako ve světě, ekonomové zabývají možnostmi vlastního modelu pro možnosti predikce bankrotu a ocenění finančního zdraví podniku. Mezi nejznámější a nejlepší modely patří od roku 1995 indexy IN vytvořené manželi Neumierovými. Tyto čtyři modely nejsou jen čistě bankrotní, ale skládají se z všestranného ohodnocení firmy. Modely z IN 95 a IN 99 jsou považovány za bankrotní modely. Naopak pozdější modely IN 01 a IN 05 mají bonitně bankrotní charakter. První z modelů IN, tedy IN 95 značně ovlivnil úpravu Altmanova Z skóre pro Českou republiku. Autoři odhadují, že indexy IN dokáží na 70 % predikovat bankrot v budoucnosti.[18]

⁴ (p) – Z aktiv se používají pouze peníze na pokladně a účtech

IN 95

Je první z řady indexů IN. Byl vytvořen na základě analýzy 24 významných matematicko-statistických modelů podnikového hodnocení. Vzorek obsahoval přes tisíc podniků. Základem celého zkoumání jsou rozdílné podmínky v domácích a zahraničních podnicích, legislativě, finančních trzích a podnikové kultuře.

$$IN95 = 0,22*CA/CZ+0,11*EBIT/NU+8,33*EBIT/CA+0,52*CV/CA+0,10*OA/KZ+16,8*ZPS/CV$$

kde CA / CZ - představuje poměr celkových aktiv a cizích zdrojů, neboli převrácený výpočet zadluženosti podniku.

EBIT / NU - je poměr zisku před zdaněním a odečtení nákladových úroků, dělený právě nákladovými úroky. Zajišťuje tedy znalost úrokového krytí a možnosti, kolik nových úvěrů by mohl ještě zisk podniku pokrýt.

EBIT / CA - poměr zisku před zdaněním a nákladovými úroky a celkových aktiv, neboli představuje klasický ukazatel rentability celkových aktiv.

CV / CA - poměr celkových výnosů vůči celkovým aktivům, důležité je zahrnout všechny položky výnosů a nejen tržby. Jde o výpočet rychlosti obratu aktiv v podniku.

OA / KZ – je poměrem oběžných aktiv proti součtu krátkodobých závazků a krátkodobých bankovních úvěrů. Jde o poměr majetku proti závazkům, které jsou kratší než jeden rok a zároveň klasický ukazatel likvidity.

ZPS/CV – závazky po lhůtě splatnosti dělené celkovými výnosy. Ukazatel typický pro evropské podmínky, zvláště pak v našem prostředí. [18]

Hranice pro jednotlivé zóny, jak bankrotní, tak aktivní se mění s každým modelem, pro tento index autoři vybrali:

IN > 2 podnik má skvělé finanční zdraví a plní své závazky bez větších potíží

2 > IN > 1 jako u ostatních modelů, šedá zóna

IN < 1 podnik je finančně nezdravý a má omezenou schopnost plnit své závazky

IN05

Je modifikací indexu IN01 a zároveň pokus o kombinace indexů IN 95 a IN 99. Jako ostatní indexy vychází z dat průmyslových podniků a jejich vzorek dosahuje úctyhodných 2000 firem. Model byl stejně jako jeho předchůdce vytvořen za základě diskriminační analýzy.

$$IN05 = 0,13*CA/CZ+0,04*EBIT/NU+3,97*EBIT/CA+0,21*CV/CA+0,09*OA/KZ$$

kde poměrové ukazatele jsou podobné jako u IN 95, s rozdíly u váhových hodnot a vynechání posledního ukazatele, tedy závazků po lhůtě splatnosti dělenými celkovými výnosy.

Hranice pro jednotlivé zóny, jak bankrotní, tak aktivní se mění s každým modelem, pro tento index autoři vybrali:

$IN > 1,6$ podnik má skvělé finanční zdraví

$1,6 > IN > 0,9$ hodnoty šedé zóny

$IN < 0,9$ podnik je na hranici úpadku nebo jej zažívá

Hranice šedé zóny a rozdělení bankrotních a aktivních podniků spočívá v několika hodnotách. První meze rozdělení je konstanta 1,60 , která tvoří hranici mezi aktivní a šedou zónou. Výsledek modelu pro společnost, který je větší než číslo 1,60 znamená zařazení do aktivní a zdravé části vzorku. Druhým neméně důležitým mezníkem je pak hodnota 0,90 určující hranici mezi šedou a bankrotní firmou. Firmy s výsledky pod 0,90 jsou hodnoceny modelem jako finančně nezdravé – bankrotní.[18]

4. ZHODNOCENÍ SOUČASNÉ EFEKTIVNOSTI VYBRANÝCH BANKROTNÍCH MODELŮ NA ZKOUMANÉM VZORKU PODNIKŮ

Tato kapitola je věnována hodnocení efektivnosti vybraných bankrotních modelů a definování zkoumaného vzorku malých a středních podniků. Dílčím cílem je charakterizovat co mají tyto podniky společného a jakým procentem se podílí na domácí ekonomice. Kromě charakteristiky je nutné také poukázat na rozdíly s velkými podniky a ve kterých parametrech se nejvíce liší. Všechny modely jsou hodnoceny v čase rok před bankrotem (T-1), důvodem je právě určení přesnosti predikce modelu v krátkém období.

4.1. Malé a střední podniky (SME)

Význam malých a středních podniků je v západních ekonomikách značný. Na procenta je například v Evropské Unii přes 90 % ze všech registrovaných podnikatelských subjektů. K ekonomickému významu přihrává navíc fakt, že například v České republice je dokonce toto procento ještě větší a malé-střední podniky se podílí na celkové zaměstnanosti téměř 60 %. Podle Ministerstva obchodu a průmyslu se SME podílí na HDP lehce přes 50 %. Jedním z hlavních přínosů SME je vytváření pracovních míst s nízkými kapitálovými náklady a rychlejší zavádění nových technologií. Velkou výhodou SME je fakt, že na rozdíl od velkých podniků jsou pružnější, nepředstavují centralizovanou moc a snadněji se ovládají. Významně urychlují regionální rozvoj a tím i růst životní úrovně obyvatelstva.

Malé podniky představují nejpružnější prvek ekonomiky. Z důvodů nízké kapitalizace musí sledovat vývojový trend trhu daleko zřetelněji než velké podniky, které mohou čerpat z rezerv a vytrvalosti. SME se daleko více musí řídit pravidly konkurenčního boje a z pohledu makroekonomie se více přibližují dokonalé konkurenci než jejich velikostní protějšek. V praxi to znamená častější inovace, zkoušení nových produktů, zavádění technologií a progresivního myšlení, které není spoutané procesními a restriktivními prvky. Z pohledu personálního řízení se SME daleko více inklinují k inovujícím řízením, domácímu prostředí a osobnějšímu přístupu. Pro rozvoj a zkušenosti pracovníků jsou tyto faktory velmi důležité.

Z hlediska bankrotu SME jsou daleko více náchylné k nedodržení svých závazků oproti velkým podnikům. Faktory, které jsou pro SME smrtelné, jako například: nezaplacení

odběratelů, ekonomická krize, odliv klíčového personálu a další politicko ekonomické problémy, jsou pro velké podniky daleko lépe stravitelné. Jak již byl zmíněno, velké podniky tvoří obrovské rezervy, mají většinou diverzifikované investice, obrovské množství kapitálu a velkou vyjednávací sílu.

Tabulka 3: Rozdělení podniků dle počtu pracovníků a aktiv

Podniky	Počet pracovníků	Velikost aktiv
Velké	> 250 osob	> 43 mil. Euro
Střední	< 250 osob	< 43 mil. Euro
Malé	< 50 osob	< 10 mil. Euro
Mikro	< 10 osob	< 2 mil. Euro

Zdroj: Vlastní úprava na základě literatury Finační analýza [21] [25]

4.2. Analyzované odvětví

Důvodem pro výběr zemědělského odvětví je jeho důležitost v lidské společnosti. Nejen, že je nejstarším odvětvím, ale zároveň jedním z nejdůležitějších. Přestože z ekonomického pohledu drží nejhorší příčky, je nutno podotknout, že je generátorem potravin, bez kterých se neobejde nikdo. V České republice jsou hlavním článkem zemědělství podniky s rostlinnou produkcí a podniky, které tuto produkci zpracovávají. Zemědělské podniky je nutno rozdělit dle jejich působení. Základem je jejich produkce, tedy jestli je rostlinná nebo živočišná. Toto rozdělení je pouze velmi povrchní. Podniky se dále dělí na přímou rostlinnou produkci nebo chov zvířat, zpracování obilovin, ostatních rostlin, masa a ostatních živočišných produktů. Některé firmy jsou pak unikátem a soustředí svou pozornost pouze na zajišťování některých služeb ve formě zakázek. Pro zemědělské podniky je typické využívání vlastního kapitálu, před kapitálem cizím. Jde o velmi neefektivní finanční řízení, které má ale své důvody. Prvním je neochota zemědělců se zadlužovat, druhým je fakt, že tyto podniky nejsou pro banky dost lukrativní, a malé podniky někdy nemají na velké půjčky.

Pro podniky v rostlinné výrobě je typická nerovnost aktiv během roku. V prvních měsících podniky nakupují zásoby a připravují se na osev. To zvyšuje oběžná aktiva a váže na něm velké množství kapitálu. V druhém období nastává orba, setí a čekání na úrodu. Tak jako u výroby se zásoby, lidská práce a dodatečné zdroje spotřebují. Aktiva tedy klesají a s tím i kapitál. Třetí období je období sklizně a tedy i značný růst oběžných aktiv. Produkce je připsána do majetku a nabízena na trhu na určitou cenu. Po prodeji


podniku zůstane zisk po odečtení veškerých nákladů. Rostliná výroba je z většiny sezónní práce a nelze ji konat v obdobích zimy.

Malé a střední podniky v živočišné výrobě mají úplně jiný přístup. Živočišná produkce si vyžaduje neustálý přísun nových zvířat. Po celý rok jsou tedy aktiva relativně stabilní, nedochází k velkým výkyvům, pouze v podobně poptávky po produkci. Tyto podniky jsou v České republice velmi závislé na dotacích. Jen málo SME dokáže v zemědělské živočišné výrobě podnikat bez podpory. Z tohoto důvodu bylo možné sledovat od roku 1992 úbytek živočišné produkce a její nahrazování produkcí rostlinnou.

4.3. Vzorek

Veškeré informace o firmách z oboru zemědělství pochází z databáze Amadeus. Jedná se vzorek firem tvořený z 25 bankrotních a 470 aktivních podniků. Podniky lze klasifikovat jako malé podniky s aktivy do 10 miliónů Euro, pohybující se na českém trhu v období od roku 2010. Pro nedostatek dat je počet bankrotních podniků pouze 25. Z databáze Amadeus se sice při prvotním exportu podařilo dostat 51 podniků, ale polovina těchto firem neobsahovala buď žádná, nebo jen částečná data.

Graf 1: Rozdělení celkového vzorku



Zdroj: Vlastní práce

4.4. Vybrané modely a jejich přesnosti

Modely jsou testovány na datech (T-1 znamená rok před bankrotem, T rok bankrotu) a výsledné přesnosti se vztahují k roku před vyhlášením bankrotu. Pro výpočet byly vybrány tyto modely:

- IN 05
- Altmanovo Z skóre 1977

- Altmanovo Z skóre 1983
- Altman Sabato model
- Altman Sabato model logaritmický

4.4.1. Index IN 05

Model IN 05 dosáhl průměrné úspěšnosti predikce úpadku zemědělských firem v roce před jejich bankrotem. Aplikace na data ukázala, že pouze 58 % aktivních podniků a 70 % bankrotních podniků dokázal model správně roztrždit a predikovat. Tyto výsledky lze považovat jako průměrné. Stejně tak i rozložení špatně určených podniků. Podniky s falešným poplachem se vyskytují okolo 32 % a s přehlédnutou hrozbou až na 24 %. Tyto faktory jsou pro model alarmující. Falešný poplach řízení firmy může vést ve většině případů k dalším analýzám, škrtům, popřípadě i šetření nákladů. Celkově modelu nevádí výrazné procento přehlédnutí tohoto typu. Pokud ale model vyhodnotí každý čtvrtý bankrotní podnik jako finančně zdravý, pak tyto podniky a jejich vedení nebudou moci sjednat opatřením a zabránit úpadku.

Tabulka č.4. ukazuje rozložení celkového vzorku podniků po aplikaci modelu IN 05. V prvním řádku lze najít rozložení aktivních firem. Modelu se podařilo v čase T-1, rok před bankrotem, ohodnotit pouze 193 z 439 podniků jako aktivních a dalších 105 zařadit do šedé zóny. Toto není nejlepší skóre, ale model si na druhou stranu dobře poradil s bankrotními podniky. Realitu naznačuje druhý řádek, který má daleko větší přesnost.

Tabulka 4: IN 05 – rozložení podniků v T-1

Reálné / Model	Aktivní	Bankrotní	Šedá zóna
Aktivní	193	141	105
Bankrotní	7	16	1

Zdroj: Vlastní výpočty

Tabulka č.5 obsahuje celkovou přesnost a rozložení vzorku dat za jednotlivé roky. Počínaje rokem T - rokem bankrotu/nebankrotu až po rok T-4. Model IN 05 během aplikace na data ukázal postupný nárůst celkové přesnosti a to z 33 % až na téměř 50 %. Tento růst je příčinou zlepšení jak přesnosti určení bankrotních tak aktivních firem. Zatímco v roce T-4 model dokázal určit pouze 128 aktivních podniků, v procentech 43,4 %, tak v čase T to již bylo úctihodných 198, tedy 56,4 %. U modelu si nelze nešimnout obrovského vlivu šedé zóny, která zahrnuje až 25 % firem. Model IN 05 je

nejpřesnější právě v roce bankrotu, to však má svou zápornou stránku, protože čím později se podniky dozví o svém finančním zdraví, tím hůře je schopný na danou situaci reagovat.


Tabulka 5: Vlastnosti modelu IN 05 na vzorku dat a jeho přesnost

IN 05 (počet podniků)	T	T-1	T-2	T-3	T-4
Správně A.	198	193	179	167	128
Správně B.	17	16	15	12	13
Špatně A.	153	141	149	164	167
Špatně B.	3	7	6	6	4
Šedá zóna	99	106	105	111	91
Přesnost A. (%)	56,4	57,8	54,6	50,5	43,4
Přesnost B. (%)	85,0	69,6	71,4	66,7	76,5
Celková přesnost (%)	47,9	40,2	39,0	33,6	33,2

Zdroj: Vlastní výpočty

Na obrázku č. 4. je vykreslena pomocí programu SPSS ROC křivka modelu IN 05. Nejblíže se horní hranici 1 (100 %) blíží křivka IN 05 T+2. Jde o data dva roky před bankrotem. Nad křivkou je ještě kolem 32 % volného místa, které dle programu v realitě neurčí model správně.

Obrázek 5: ROC křivka modelu IN 05



Zdroj: Vlastní výpočty v SPSS

4.4.2. Altmanovo Z skóre 1977

Model Z skóre z roku 1977 dosáhl stabilně průměrné úspěšnosti predikce úpadku zemědělských firem ve všech hodnocených letech. Z celkového počtu 440 podniků, vždy určil bankrotní podniky na 90 až 100 %. To jej dělá nesmírně výborným modelem i přesto že celková přesnost za jednotlivé roky není nějak velká. Důležité pro bankrotní model je určit právě podniky, kterým hrozí úpadek. Altmanovo Z skóre toto kritérium splňuje s obrovskou rezervou. Pro management a bonitní společnosti je důležité vyvarovat se přehlédnutým hrozbám. U aktivních podniků, již Z skóre 77 tak přesné není, naopak je většinou popráůměrné. Nejvyšší hodnota 50,4 % v čase T-1 poukazuje na přesnost modelu. Model je velmi náročný a tudíž hodnotí většinu aktivních podniků jako bankrotní. Tento model doporučuji používat pouze jako bonitní nebo pro udělování náročnějších investic. Pokud ve výsledku podnik vychází jako aktivní je velká pravděpodobnost, že jde o silný podnik s dobrým finančním zdravím.

Tabulka č.6. znázorňuje rozložení celkového vzorku podniků po aplikaci modelu Z skóre 77. První řádek tvoří rozdělení firem aktivních a druhý bankrotních v čase T-1. Modelu se podařilo v tomto čase vyhodnotit pouze 176 z 440 podniků jako aktivních a dalších 105 zařadit do šedé zóny. Toto není nejlepší skóre, ale model si na druhou stranu dobře poradil s bankrotními podniky.

Tabulka 6: Z skóre 77 – rozložení podniků v T-1

Reálné / Model	Aktivní	Bankrotní	Šedá zóna
Aktivní	176	174	90
Bankrotní	1	21	2

Zdroj: Vlastní zpracování

Tabulka č.7 je tvořena přesnostmi a rozložením vzorku dat za jednotlivé roky. Počáteční rok T-4 ohodnotil nejméně podniků z celého modelu. Důvodem je nejspíše fakt, že některé firmy jsou poměrně mladé. V tabulce jsou však i velmi důležité informace. První kterou je nutno zmínit je maximální přesnost při určení bankrotního podniku. Druhou neméně důležitou je fakt, že celková přesnost modelu by mohla být zlepšena. Při testování dat bylo možné zaznamenat lehké odchylky hranic, které kdyby byly upraveny, mohl by si model zachovat svoji přesnost v bankrotní zóně a zlepšit si určení aktivního podniku.


Tabulka 7: Vlastnosti modelu Z skóre 77 na vzorku dat a jeho přesnost

Alt 77 (počet podniků)	T	T-1	T-2	T-3	T-4
Správně A.	169	176	166	166	130
Správně B.	20	21	18	18	15
Špatně A.	180	173	172	182	165
Špatně B.	1	1	1	1	0
Šedá zóna	100	92	97	96	96
Přesnost A. (%)	48,4	50,4	49,1	47,7	44,1
Přesnost B. (%)	95,2	95,5	94,7	94,7	100,0
Celková přesnost (%)	46,1	48,1	46,5	45,2	44,1

Zdroj: Vlastní zpracování

Na obrázku č.5 je znázorněna ROC křivka modelu Z skóre 77. I přesto, že celková přesnost modelu vyšla průměrně, křivka poukazuje na určité faktory, které již byly zmíněny při popisu modelu. Prvním je stálost přesnosti. ROC křivky jsou poměrně podobné a nejsou strmě. Tudíž i výsledky modelů jsou spíše konstantní. Mezi křivkami a základní linií lze vidět standartní část vzorku, kterou model vždy určil správně.

Obrázek 6: ROC křivka modelu Z skóre 77



Zdroj: Vlastní zpracování v SPSS

4.4.3. Altmanovo Z skóre 1983

Z skóre z roku 1983 dosáhlo velmi podobných skóre jako jeho předchůdce. Charakterizuje je znovu průměrná úspěšnost predikce úpadku zemědělských firem ve všech hodnocených letech s kombinací nadstandartních výsledků v určení bankrotních podniků. Z celkového počtu 463 podniků, vždy určil bankrotní podniky na 90 až 100 %. To dělá Altmanovi Z skóre velmi kvalitní a přísné modely. U aktivních podniků má model značné nedostatky. Díky tvrdým kritériím často hodnotí podniky jako bankrotní nebo je posílá do šedé zóny. Skvělým příkladem je tabulka č. 8., která zaznamenává přesnost Z skóre v čase T-1. Jak již bylo řečeno, model dokázal s přesností určit 19 z 22 bankrotních podniku a navíc ještě 2 dokázal zařadit alespoň do šedé zóny. Co se týče aktivních podniků Z skóre si již nepočíná tak dobře. V čase T-1 určilo pouze 137 podniků správně, 145 špatně a 158 zařadilo do šedé zóny. Tento fakt ničí celkovou přesnost modelu a zastiňuje jeho silné stránky.

Tabulka 8: Z skóre 83 – rozložení podniků v T-1

Reálné / Model	Aktivní	Bankrotní	Šedá zóna
Aktivní	137	145	158
Bankrotní	1	19	2

Zdroj: Vlastní zpracování

Kompletní přesnost Altmanova Z skóre 83 obsahuje tabulka č. 9. Tak jako u předchozích modelů obsahuje test modelu na datech podniku za posledních pět let jeho fungování. Model si dle tabulky nevedl špatně. Za každý rok dokázal určit minimálně 94,7 % všech bankrotních podniků. Senzací je pak rok T-4 kde model určil 100 %, tedy 15 / 15 bankrotních podniků a ani jediný neposlal do šedé zóny. V dalších letech počet podniků, které model dokázal ohodnotit ztoupil z 15 na 20. Podnik, který byl v čase T-4 v šedé zóně se přelil do aktivních a od tohoto času jej Z skóre klasifikovalo špatně. U aktivních podniků se přesnost během zkoumaného času lehce zvyšovala. Z počátečních 41,3 % o šest procentních bodů na hranici 47,1 %. Jak u Z skóre 77 ani tento model dokázal určit méně než 50 %. S růstem počtu podniků se poměrově i zvyšovala šedá zóna. Vyrostl z počátečních 166 až na počet 173 neklasifikovaných podniků. Toto číslo je velmi vysoké a tím, že zahrnuje jak aktivní tak bankrotní podniky, je velmi těžké určit, zda by posunutí hranic zóně pomohlo.


Tabulka 9: Vlastnosti modelu Z skóre 83 na vzorku dat a jeho přesnost

Alt 83 (počet podniků)	T	T-1	T-2	T-3	T-4
Správně A.	131	137	121	123	93
Správně B.	18	19	18	17	15
Špatně A.	147	144	143	153	132
Špatně B.	1	1	1	1	0
Šedá zóna	173	160	171	169	166
Přesnost A. (%)	47,1	48,8	45,8	44,6	41,3
Přesnost B. (%)	94,7	95,0	94,7	94,4	100,0
Celková přesnost (%)	44,6	46,3	43,4	42,1	41,3

Zdroj: Vlastní zpracování

Na obrázku č.6. jsou vykresleny ROC křivky modelu Z skóre 83. Podobně jako u předchozího modelu, celková přesnost vyšla průměrně, ale křivka poukazuje na určité faktory, které model dělají vyjimečným. Jde hlavně o stálost přesnosti, ROC křivky jsou poměrně podobné a nejsou strmé, tudíž i výsledky modelů jsou spíše konstantní. Mezi křivkami a základní linií lze i vidět standartní část vzorku, kterou model vždy určil správně.

Obrázek 7: ROC křivka modelu Z skóre 83



Zdroj: Vlastní zpracování

4.4.4. Altman Sabato model

Altman Sabato model dosáhl přesně opačných výsledků jako je Z skóre z roku 77 nebo 83. Model charakterizuje úspěšnost predikce aktivních podniků. Ve velké míře tomuto přispívá absence šedé zóny, která by alespoň ohraničila sporné podniky. Model dokázal rozlišit 275 z 296 aktivních zemědělských podniků. Tento fakt mu vynáší hodnocení kolem 93 % a i v předešlých a následujících časových obdobích je model úspěšný. Druhou, negativní, charakteristikou je neschopnost určit bankrotní podnik.

V tabulce č. 10. je vyobrazena aplikace modelu Altman Sabato na data v čase T-1. Jak již bylo zmíněno model snadno nalezne aktivní podnik, ale chybí mu přesnost pro bankrotní. V čase T-1 dosahuje druhých nejvyšších přesností během testování. Jde o 92,9 % u aktivních a 42,2 % u bankrotních.

Tabulka 10: Altman Sabato model – rozložení podniků v T-1

Reálné / Model	Aktivní	Bankrotní
Aktivní	275	21
Bankrotní	10	7

Zdroj: Vlastní zpracování

Kompletní vlastnosti a přesnost zobrazuje tabulka č. 11. Zatímco u jiných modelů lze pozorovat nárůst přesnosti s blížícím se bankrotem, u modelu Altman Sabato je tomu naopak. Procentuální přesnost v předposledním řádku naznačuje jasný klesající trend po dovršení času T-2. Zatímco nejvyšší přesnost bankrotních podniků je v tomto čase 53,3 % v čase T je to pouze 16,7 %. Z tabulky však vyplývají i pozitivní faktory modelu. Těmi jsou hlavně rostoucí přesnost určení aktivních podniků během času a možnost zlepšení modelu zasazením šedé zóny nebo jinou úpravou.


Tabulka 11: Vlastnosti modelu Altman Sabato na vzorku dat a jeho přesnost

AS nlg (počet podniků)	T	T-1	T-2	T-3	T-4
Správně A.	277	275	257	243	216
Správně B.	2	7	8	5	5
Špatně A.	28	21	27	30	35
Špatně B.	10	10	7	9	8
Přesnost A. (%)	90,8	92,9	90,5	89,0	86,1
Přesnost B. (%)	16,7	41,2	53,3	35,7	38,5
Celková přesnost (%)	15,1	38,3	48,3	31,8	33,1

Zdroj: Vlastní zpracování

Obrázek č.7. vypovídá o ROC křivkách modelu Altman Sabato. Lze si povšimnout velmi velkých výkyvů jednotlivých křivek. Důvodem je právě přesnost modelu. Zatímco se křivky blíží ke maximální hranici přesnosti modelu 100 %, celková přesnost tvrdí pravý opak. Jde pouze však o úhel pohledu. Křivky nerozlišují s takovou silou aktivní a bankrotní a řídí se pouze výsledkem souhlasí / nesouhlasí. Pokud by model Altman Sabato měl více bankrotních podniků k hodnocení, a ohodnotil by je špatně, křivky by klesaly, ne kvůli poklesu přesnosti, ale kvůli celkovým datům v modelu.

Obrázek 8: ROC křivka modelu Altman Sabato



Zdroj: Vlastní zpracování

4.4.5. Altman Sabato model logaritmovaný

Altman Sabato logaritmický model se může zdát na první pohled podobný díky stejným poměrovým ukazatelům, ale u testování dat je poznat veliký rozdíl. Nejdůležitějším je zvýšení celkové přesnosti modelu o skoro 30 – 50 %. Logaritmus zde hraje funkci odmocnitele a předělává veškerá data na rozdílově menší konstanty. Příkladem jsou právě průměrné mezní rozdíly v obou modelech. Zatímco u Altman Sabato byly rozdíly v řádech jednotek, u logaritmu jde o setiny.

Zlogaritmovaný Altman Sabato model dosahuje podobných výsledků jako jsou model Z skóre nebo IN 05. Model již nedokáže určit ani 70 % aktivních podniků, ale na druhou stranu zvýšil svoji průměrnou přesnost z 25 % na 55 %. Toto je obrovský posun, který se podepisuje na celkové přesnosti modelu.

Tabulka č. 12. obsahuje jedny z nejlepších výsledků vybraných modelů. V druhém řádku jsou data bankrotních podniků a i když je jich jen osm, model je všechny zařadil správně. První řádek tvoří aktivní podniky. Z 254 jich model určil 160 jako aktivních. Tato kombinace 100 % bankrotních a jakýkoliv počet aktivních dává modelu možnost zasazení šedé zóny a zlepšení přesnosti.

Tabulka 12: Altman Sabato model log – rozložení podniků v T-1

Reálné / Model	Aktivní	Bankrotní
Aktivní	160	94
Bankrotní	0	8

Zdroj: Vlastní zpracování

Podobně jako u předešlých modelů, tabulka č. 13 obsahuje vlastnosti modelu a jeho přesnost na celkovém vzorku dat. Oproti svému předchůdci logaritmický model je velmi přesný. Od časového úseku T-4 po T se model dostal na kvalitních 62,8 %. Jde o velmi přesný model se 100 % přesností bankrotních podniků ve dvou letech po sobě. Vlastnosti modelu jsou po analýze tabulky hlavně rostoucí přesnost bankrotních podniků až ke svému maximu a stálá přesnost, kolem 62,5 % u aktivních podniků. Nevýhodou modelu je jeho malá aplikovatelnost v rámci celkového vzorku. Pouze polovina dat byla schopná projít do hodnocení. Důvody jsou za prvé, logaritmus a jeho vlastnosti (bankrotní podniky mají dost záporných dat a logaritmus je nedokáže hodnotit), druhým důvodem je složitost modelu a váhy přiřazené jednotlivým ukazatelům.


Tabulka 13: Vlastnosti modelu Altman Sabato logaritmický na datech a jeho přesnost

AS lg (počet podniků)	T	T-1	T-2	T-3	T-4
Správně A.	164	160	156	140	123
Správně B.	8	8	5	5	4
Špatně A.	97	94	83	83	76
Špatně B.	0	0	1	1	2
Přesnost A. (%)	62,8	63,0	65,3	62,8	61,8
Přesnost B. (%)	100,0	100,0	83,3	83,3	66,7
Celková přesnost (%)	62,8	63,0	54,4	52,3	41,2

Zdroj: Vlastní zpracování

Obrázku č.8. jsou znázorněny ROC křivky logaritmického modelu Altman Sabato. Lze si povšimnout minimálních výkyvů jednotlivých křivek. Důvodem je právě přesnost modelu, kdy na rozdíl od minulého modelu křivky se celková přesnost se shoduje. Model určí kolem 60 – 70 % veškerých podniků správně, bez rozdílu bazické proměnné (je-li je aktivní nebo bankrotní).

Obrázek 9: ROC křivka modelu Altman Sabato logaritmický



Zdroj: Vlastní zpracování

4.4.6. Celkové hodnocení modelů

Tato kapitola shrnuje veškeré poznatky o vybraných modelech a obsahuje jejich bodové ohodnocení. Tabulka č. 14 zahrnuje úspěšnost vybraných modelů v čase T -1. Výsledky jsou velmi obdivné právě časovým úsekem. Všechny modely totiž dosáhly svých nejlepších přesností v tomto čase. Celkové přesnosti i bodové hodnocení se bude značně lišit. Z tabulky vychází úspěšnosti predikce modelů a počet podniků v šedé zóně.


Tabulka 14: Úspěšnost bankrotních modelů v čase T-1

Modely (T-1)	Aktivní		Bankrotní		Šedá zóna		Celkem podniků
	Počet	Procento	Počet	Procento	Počet	Procento	
IN 05	19	57,78	16	69,57	106	22,89	463
Z skóre 77	176	50,3	21	95,45	92	19,83	464
Z skóre 83	137	48,58	19	95,5	160	34,63	462
AS nlog	275	92,91	7	41,18	0		313
AS log	160	62,99	8	100,00	0		262

Zdroj: Vlastní zpracování

Graf č.2 zahrnuje vybrané modely a jejich přesnost v určení aktivních podniků vůči realitě. Z grafu lze ihned poznat, že největší přesnot, 92,91 %, disponuje model Altman Sabato. Na dalších místech pak následují modely Altman Sabato logaritmický 62,99 %, IN 05 43,96 %, v těsné blízkosti Z skóre 77 s 40 % a poslední se umístil model Z skóre 83 s 31,14%.

Graf 2: Úspěšnost predikce aktivních podniků v čase T-1




Zdroj: Vlastní zpracování

Hodnocení úspěšnosti predikce bankrotu na celkovém vzorku podniků popisuje graf č. 3. Podobně jako graf č. 2 má jediný nedostatek. Výsledky jsou velmi oblivněny časovým úsekem T-1, kde všechny vybrané modely dosáhly svých predikčních maxim. Bezkonkurenčně nejlepším model pro predikci bankrotu je Altman Sabato model logaritmický s 100 %. Na dalších místech se umístily modely Z skóre 77 s 83,36 % a

Z skóre 83 s 86,36 %. Předposlední se umístil model IN 05 s 66,67 % a na posledním je Altman Sabato model s 41,18 %.


Graf 3: Úspěšnost predikce bankrotních podniků v čase T-1



Zdroj: Vlastní zpracování

Graf č.4 zahrnuje vybrané modely u kterých je definovaná šedá zóna. Tyto modely, IN 05, a Z skóre v průměru nezařadily kolem 26 % veškerých dat. To vede ke středním výsledkům, které je možné najít v následujících tabulkách.

Graf 4: Podniky zařazené do šedé zóny v čase T-1



Zdroj: Vlastní zpracování

Přehled o chybně zařazených podnicích ve vybraných modelech v čase T-1 poskytuje tabulka č. 15. Je komplexní tabulkou zahrnující počet a procento chybných podniků spolu s celkovým počtem podniků, které byl model schopen ohodnotit. Je zároveň inverzní tabulkou na tabulku č. 14.

Tabulka 15: Chybně zařazené podniky v čase T-1

Modely	Aktivní		Bankrotní		Šedá zóna		Celkem podniků
	Počet	Procento	Počet	Procento	Počet	Procento	
IN 05	141	32.12	7	29.17	106	22.89	463
Z skóre 77	174	39.55	1	4.17	92	19.83	464
Z skóre 83	145	32.95	1	4.55	160	34.63	462
AS nlog	21	7.09	10	58.82	0		313
AS log	94	37.01	0	0.00	0		262

Zdroj: Vlastní zpracování

Tabulka č. 16. obsahuje konečné hodnocení vybraných modelů dle předem vytyčených kritérií. Prvním je hodnocení neúspěšnosti určení aktivního podniku – tedy falešný poplach, druhým je hodnocení neúspěšnosti predikce bankrotu – tedy přehlédnutá hrozba a posledním kritériem je hodnocení aplikovatelnosti modelu na vzorek dat. Důvody proč byla vybrána tato kritéria jsou zjevné, rozlišení chyb u aktivních a bankrotních podniků je předmětem více vědeckých prací. Jedinou výjimkou je aplikovatelnost na data, která by se mohla zdát velmi nespravedlivá. Názor je takový, že model musí být hodnocen i podle toho jak dokáže v dané zemi nebo oblasti vyhodnocovat podniky. Jednotlivé hodnocení bylo stanoveno 1 bod za falešný poplach, dále bylo navrhuto 10 bodů za přehlédnutou hrozbu, ale díky rozložení aposteriorní pravděpodobnosti 80:20 pro bankrotní podniky, bylo přistoupeno na 5 bodů za hrozbu. Posledním faktorem, aplikovatelností dat bylo přiřazeno půl bodu z důvodů co nejmenšího zkreslení výsledků. Hodnocení spočívá v opačné stupnici, tedy čím více bodů model dostane, tím je horší. Nejlepším vybraným modelem je Altmanovo Z skóre z roku 1983, těsně následované modelem Altman Sabato logaritmický. Díky vysoké přesnosti určení bankrotních podniků a nadpolovičním určení podniků aktivních tyto modely získali jen 57 a 59 záporných bodů. Následuje na třetím místě Z skóre z roku 1977 se 62 zápornými body, index IN 05 se 179 body a poslední se umístil Altman Sabato model s 318 body.

Tabulka 16: Bodové hodnocení modelů v čase T-1 na základě chybovosti

Modely	Body (Za falešný poplach 1b)	%	Body (Za přehlédnutou hrozbu 5b)	%	Neaplikovatelnost na data (0,5b)	%	Body celkem
Z skóre 83	33	33	23	5	1	3	57
AS log	37	37	0	0	22	44	59
Z skóre 77	40	40	21	4	1	2	62
IN 05	32	32	146	29	1	2	179
AS nlog	7	7	294	59	17	34	318

Zdroj: Vlastní zpracování

5. NÁVRH VLASTNÍHO MODELU BANKROTU

Tato kapitola je věnována tvorbě nového bankrotního modelu pomocí aplikace lineární diskriminační analýzy na testovací a celkový vzorek dat. Modely s výraznou přesností budou dále podrobeny zkoumání, výpočtům a určování šedé zóny. Cílem je určit jeden nebo více modelů, které budou v hodnocení podobné nebo lepší než bankrotní modely z předešlé kapitoly. Vzhledem k rozmanitosti a složitosti tvorby modelů, bylo potřeba nejen vybrané modely hodnotit, ale i inspirovat se autory a jejich unikátní tvorbou.

5.1. Testovací vzorek

Testovací vzorek byl určen pomocí funkce náhodného čísla v programu MS Excel. Pro přesnější výpočet bylo do testovacího vzorku přiřazeno malé procento bankrotních podniků navíc. Tento akt je ospravedlněn faktem, že v testovacím vzorku se objevilo pouze 10 % bankrotních firem. Při vzorku 20 firem je toto však velmi malé procento, které by značně výsledný model zkreslilo, nebo nebylo schopno přesně určit. V programu Statistika 12 byla pro testovací vzorek dále upravena aposteriorní pravděpodobnost na rozložení bankrotní podniky 80 % a aktivní 20 %. Testovací vzorek nakonec obsahoval 8 bankrotních a 48 aktivních podniků.

5.2. Podílové ukazatele

Prvním krokem je výběr nekorelovaných ukazatelů. Poté v programu Statistika 12 jsou testovány ukazatele pomocí lineární diskriminační analýzy. Ukazatelé jsou následně promýcháni a testováni vůči sobě. Program napomůže určit ukazatele, jejíž součet, se nejvíce podobá rozložení bazické proměnné. Bazická proměnná je v podnikových datech základní proměnná rozdělující vzorek na bankrotní a aktivní podniky. Čím větší procento bazické proměnné vůči výsledkům modelu je podobných, tím větší je přesnost modelu. Tabulka č. 17. obsahuje veškeré testované podílové proměnné. Jde o souhrn 22 proměnných používaných v odborné literatuře, podnikové ekonomii a ostatních bankrotních modelech.

Tabulka 17: Testované podnikové ukazatele

Zkratka	Proměnné
OD/CA	Odpisy / Celková aktiva
CF/CZ	Cashflow / Cizí zdroje
OA/CA	Oběžná aktiva / Celková aktiva
EBIT/CA	Zisk / Celková aktiva
CZ/CA	Cizí zdroje / Celková aktiva
CA/CZ	Celková aktiva / Cizí zdroje
TR/CA	Tržby / Celková aktiva
OA/CZ	Oběžná aktiva / Cizí zdroje
CZ/(EAT+OD)	Cizí zdroje / (Čistý zisk + Odpisy)
DHM/OD	Dlouhodobý hmotný majetek /Odpisy
OA-KZ-BU/ ZA	(Oběžná aktiva – krátkodobé cizí zdroje – bankovní úvěry) / Zásoby
VK/CA	Vlastní kapitál / Celková aktiva
TR/OA	Tržby / Oběžná aktiva
EAT/VK	Zisk / Vlastní kapitál
EAT/ NU	Zisk / Nákladové úroky
OA/KZ	Oběžná aktiva / Krátkodobé závazky
PK/CA	Pracovní kapitál / Celková aktiva
KZ/VK	Krátkodobé závazky / Vlastní kapitál
PE/CA	Peníze / Celková aktiva
EBIT/TR	Zisk / Tržby
NZ/CA	Nerozdělený zisk / Celková aktiva
NZ/VK	Nerozdělený zisk / Vlastní kapitál

Zdroj: Inspirováno literaturou [14][19][21]

5.3. Korelace

K tomu, aby mohla jakákoliv diskriminační analýza fungovat, potřebuje k výpočtu co nejméně korelované proměnné. Jeden z prvních výpočtů je tedy, určení jednotlivých korelací mezi zvolenými ukazateli. Pomocí programu Statistika 12 byla provedena korelační analýza. Z důvodů obsáhlosti výsledné tabulky jsou zmíněny pouze výsledky, které jsou rozhodující pro následující kroky. Největší korelaci zaznamenali proměnné CA/CZ a CZ/CA, což vzhledem k jejich převrácené hodnotě není nic průlomového. Naopak VK/CA a CZ/CA, které dostali hodnotu jedna, už znamenají přímou korelaci a tudíž se VK/CA neobjevuje dále ve výpočtu. Následující proměnné EAT/NU a EBIT/TR disponují značnou mírou korelace na svůj protějšek EBIT/CA. Protože EBIT/CA není korelován s ničím jiným a ostatní zmíněné proměnné ano, je v práci ponechán. Poslední proměnnou, která nebyla do modelu zařazena z důvodů vysoké korelace na majetkové ukazatele je OA/CZ.

Proměnné vynachané z LDA:

- CA/CZ (-1,00 ; 1,00)
- OA/CZ (0,773)
- VK/CA (0,773 ; 1,00)
- EAT/NU (0,755)
- EBIT/TR (0,751 ; 0,771)

Aby mohla být počítána LDA pro zlogaritmované proměnné je potřeba nejprve provést korelační analýzu. Znovu z důvodů obsáhlosti výsledné tabulky jsou zmíněny pouze výsledky, které jsou rozhodující pro následující kroky. Největší korelaci zaznamenaly znovu proměnné CA/CZ a CZ/CA, což není žádným překvapením. Ukazatel EBIT/CA, který dosáhl velké hodnoty okolo 0,84 v návaznosti na ukazatele obsahujícím zisk, z tohoto důvodu se ve výpočtu neobjeví. Další proměnné VK/CA a Zisk/TR disponují značnou mírou korelace na své soky EAT/VK a OA/CA.

Proměnné vynechané z LDA:

- CA/CZ (-1,00)
- OA/KCZ (0,61 ; 0,68)
- VK/CA (0,61 ; 1,00)
- EBIT/TR (0,62 ; 0,67)

5.4. Tvorba modelů

Základem modelotvorby je testování jednotlivých poměrových ukazatelů, které probíhá ve více fázích. První krok byl určit testovací vzorek a optimalizovat jej o velmi korelované ukazatele. Pokračováním vedlo k využití softwaru Statistika 12 a vícerozměrné diskriminační analýzy. V rámci diskriminační analýzy bylo potřeba projít jednotlivé proměnné a jejich kombinace a porovnávat je oproti základní bazické proměnné (statusu podniku – bankrotní / aktivní). Kombinace ukazatelů s největší výpovědní schopností byly postoupeny testu na celkovém vzorku dat. V následujících podkapitolách se práce věnuje jednotlivým modelům. Vzhledem k tomu, kolik bylo testováno možností, nelze se zde setkat se všemi výsledky, ale pouze s modely, jejichž testovací nebo celkové matice byly alepoň trochu přesné.

5.4.1. Model X(n1)(d)

Prvním model, který po testech vyšel s velmi kvalitními výsledky je model označený X(n1)(d). Důvodem je nejen přehlednost ve výpočtech, ale i zkratky pro použití dat v celkovém hodnocení. Jde o propočet modelu ve softwaru Statistika 12. Data ze kterých model vychází jsou označena X – tedy nelogaritmická data, pouze dosazená do proměnných. N1 je označení modelu, jeho pořadové číslo dle historie výtvaru. Zkratka (d) je posledním ze druhu označení, znázorňující jestli jde v modelu o použití zpětné nebo v tomto případě dopředné diskriminační analýzy.

Tabulka č. 18 znázorňuje klasifikační funkci modelu. Jde o jeden z dílčích výsledků diskriminační analýzy. Klasifikační funkce se skládá z pěti proměnných a jejich rozdělení, váhou a vztahem pro aktivní a bankrotní podniky. Poslední sloupec pak obsahuje přímý výpočet váhy jednotlivých proměnných pomocí odečtení bankrotních vah od aktivních. Sloupec A-B je tvořen váhovými koeficienty, které v modelu budou násobit proměnné a upravovat tak jejich poměrové zastoupení v modelu. Někdy silnější vážené proměnné v modelu jsou tedy peníze dělené celkovými aktivy s váhou 23 962 a cashflow dělené cizími zdroji s váhou 2131. Obrovskou zápornou hodnotu dosahuje také konstanta, jde o číslo -23 164. Naopak nejslabší vážené ukazatele jsou čistý zisk dělený nákladovými úroky a krátkodobé závazky dělené vlastním kapitálem s hodnotou 34.

Tabulka 18: Klasifikační funkce pro model X(n1)(d)

Klasifikační funkce			
Proměnné	B = 12 %	A = 88 %	A-B
PE/CA	305	24266	23962
PK/CA	7	772	766
EAT/NU	0	-17	-17
KZ/VK	1	35	34
CF/CZ	77	2208	2131
Konstanta	-8	-23172	-23164

Zdroj: Vlastní zpracování

Klasifikační matice modelu pro testovací vzorek dat je obsahem tabulky č. 19. Model pomocí vážených proměnných dokázal určit 100 % testovacích dat. Pro pořádek je jsou v řádcích obsažena reálná data a model naváže pomocí sloupců (do kolonek BA a AB) o kolik se liší model realitě. V tomto případě jsou jakékoliv rozdíly rovny nule.

Tabulka 19: Test reprezentativního vzorku pro model X(n1)(d)

Klasifikační matice – test t.v.			
Skupina	Procenta	B = 12 %	A = 88 %
B	100 %	6	0
A	100 %	0	43

Zdroj: Vlastní zpracování

Pomocí klasifikační funkce a výsledků klasifikační matice, byl sestaven výsledný model. Základ tvoří pět vážených proměnných a odečet konstanty. Model byl dále testován na celkovém vzorku.

$$\text{MODEL}_1 = -23164 + 23962 \cdot \text{PE/CA} + 766 \cdot \text{PK/CA} - 17 \cdot \text{EAT/NU} + 34 \cdot \text{KZ/VK} + 2131 \cdot \text{CF/CZ}$$

kde PE/CA – peníze / celková aktiva, PK/CA – pracovní kapitál / celková aktiva, EAT/NU – čistý zisk / nákladové úroky, KZ/VK – krátkodobé závazky / vlastní kapitál, CF/CZ – cashflow / cizí zdroje.

Tabulka č.20. znázorňuje rozložení bankrotních a aktivních podniků ve sloupcích v kombinaci s realitou v řádcích. Z aktivních podniků výsledný model dokázal určit skvělých 99 % podniků, tedy 286 z celkových 288. U bankrotních naopak byl model velmi slabý a pouhých 14 %, 2 ze 14 podniků označil bez chyby. Váha bazické proměnné byla určena poměrem bankrotních a aktivních podniků v celkovém vzorku.

Tabulka 20: Test celkového vzorku pro model X(n1)(d)

Klasifikační matice – test c.v.			
Skupina	Procenta	B = 5 %	A = 95 %
B	14,28 %	2	12
A	99,31 %	2	286

Zdroj: Vlastní zpracování

MODEL₁ z důvodů slabé přesnosti nebyl zařazen do užšího výběru a tudíž i další výsledky, jako je určení šedé zóny nebo rozbor diskriminační funkční analýzy nebudou uvedeny. Celkové hodnocení tohoto modelu lze najít v tabulce č. 38. na konci další kapitoly 5.5.

5.4.2. Model $X(n1)(z)$

Klasifikační funkci modelu $X(n1)(z)$ lze najít v tabulce č. 21. Podobně jako v minulém modelu i tady jde o použití stejných dat, ale velkým rozdílem je použití zpětné krokové analýzy. Klasifikační funkce se skládá ze třech proměnných a jejich rozdělení, váhou a vztahem pro aktivní a bankrotní podniky. Nejslabší vážené ukazatele jsou čistý zisk dělený nákladovými úroky s hodnotou -14. Naopak nejsilnější váženou proměnnou v modelu jsou peníze dělené celkovými aktivy s váhou 23 962, zároveň obrovskou zápornou hodnotu dosahuje také konstanta -18 249.

Tabulka 21: Klasifikační funkce pro model $X(n1)(z)$

Klasifikační funkce			
Proměnné	B = 12 %	A = 88 %	A-B
PE/CA	202	20749	20547
PK/CA	6	744	738
EAT/NU	0	-14	-14
Konstanta	-4	-18252	-18249

Zdroj: Vlastní zpracování

Klasifikační matice testovacího vzorku modelu $X(n1)(z)$ je obsahem tabulky č. 22. Model pomocí vážených proměnných dokázal určit stejně jako jeho dopředný protějšek 100 % testovacích dat. Buňky BA a AB jsou i v tomto případě prázdné.

Tabulka 22: Test reprezentativního vzorku pro model $X(n1)(z)$

Klasifikační matice – test t.v.			
Skupina	Procenta	B = 12 %	A = 88 %
B	100 %	6	0
A	100 %	0	43

Zdroj: Vlastní zpracování

Pomocí klasifikační funkce a výsledků klasifikační matice, byl sestaven výsledný model. Základ tvoří tři proměnné a záporná konstanta. Model byl dále testován na celkovém vzorku.

$$\text{MODEL}_2 = -18249 + 20547 \cdot \text{PE/CA} + 738 \cdot \text{PK/CA} - 14 \cdot \text{EAT/NU}$$

kde PE/CA – peníze / celková aktiva, PK/AC – pracovní kapitál / celková aktiva, EAT/NU – čistý zisk / nákladové úroky

Tabulka č.23. odbahuje rozložení bankrotních a aktivních podniků ve sloupcích v kombinaci s realitou v řádcích. Z aktivních podniků výsledný model dokázal určit

úctyhodných 98 %, tedy 420 z celkových 428. U bankrotních naopak byl model velmi slabý - pouhých 18 %, 4 ze 22 podniků označil bezchybně. Váha bazické proměnné byla určena podobně jako u dopředné analýzy, poměrem bankrotních a aktivních podniků.

Tabulka 23: Test celkového vzorku pro model $X(n1)(z)$

Klasifikační matice – test c.v.			
Skupina	Procenta	B = 5 %	A = 95 %
B	18,18 %	4	18
A	98,13 %	8	420

Zdroj: Vlastní zpracování

MODEL₂ z stejného důvodu jako MODEL₁ nebyl zařazen do užšího výběru a tudíž i další výsledky, jako je určení šedé zóny nebo rozbor diskriminační funkční analýzy nebudou uvedeny. Celkové hodnocení tohoto modelu lze najít v tabulce č. 38.

5.4.3. Model $X(n2)(d)$

Model Model $X(n2)(d)$ je velmi podobný svým předchůdcům. Je založený na nejlepších ukazatelích minulých modelů v kombinaci s ukazateli, které nebyli nebo neprošli testováním poprvé. Klasifikační funkci modelu $X(n2)(z)$ obsahuje tabulka č. 24. Klasifikační funkce se skládá tentokrát ze šesti proměnných. Nejslabší vážené ukazatele jsou čistý zisk dělený vlastním kapitálem a cizí zdroje dělené součtem čistého zisku a odpisů s váhou 0,005. Naopak nejsilnější váženou proměnnou v modelu jsou opět peníze dělené celkovými aktivy s váhou 9,918.

Tabulka 24: Klasifikační funkce pro model $X(n2)(d)$

Klasifikační funkce			
Proměnné	B = 12 %	A = 88 %	A-B
CZ/(EAT+OD)	-0,0045	0,0004	0,005
EAT/VK	-0,0017	0,013	0,015
OA/KZ	0,02673	0,125	0,099
PK/CA	0,06456	0,803	0,739
PE/CA	2,798	12,716	9,918
NZ/CA	-0,291	-0,142	0,149
Konstanta	-0,997	-1,490	-0,493

Zdroj: Vlastní zpracování

Klasifikační matice testovacího vzorku modelu $X(n1)(d)$ je obsahem tabulky č. 25. Model pomocí vážených proměnných dokázal určit stejně jako předchůdci 100 % testovacích dat.

Tabulka 25: Test reprezentativního vzorku pro model X(n2)(d)

Klasifikační matice – test t.v.			
Skupina	Procenta	B = 12 %	A = 88 %
B	100 %	6	0
A	100 %	0	43

Zdroj: Vlastní zpracování

Výsledky klasifikační matice spolu s klasifikační funkcí pomohli sestavit výsledný model. Základ tvoří šest proměnných a záporná konstanta. Model byl dále otestován na celkovém vzorku.

$$\text{MODEL}_3 = -0.493 + 0.005 * \text{CZ}/(\text{EAT} + \text{OD}) + 0.015 * \text{EAT}/\text{VK} + 0.099 * \text{OA}/\text{KZ} + 0.739 * \text{PK}/\text{CA} + 9.918 * \text{PE}/\text{CA} + 0.149 * \text{NZ}/\text{CA}$$

kde CZ/(EAT+OD) – cizí kapitál / součet čistého zisku a odpisů majetku, EAT/VK – čistý zisk / vlastní kapitál, OA/KZ – oběžná aktiva / krátkodobé závazky, PK/CA – pracovní kapitál / celková aktiva, PE/CA – peníze / celková aktiva, NZ/CA – nerozdělený zisk / celková aktiva

Tabulka č.26. odbahuje rozložení bankrotních a aktivních podniků ve sloupcích v kombinaci s realitou v řádcích. Z aktivních podniků výsledný model dokázal určit nadprůměrných 72 %, tedy 194 z celkových 269. U bankrotních naopak byl model velmi přesný a pouhých 18 % (4 ze 22 podniků) označil špatně. Váha bazické proměnné byla určena pomocí aposteriorní pravděpodobnosti s rozdělením váhy bankrotní 0,8 a aktivní pouze 0,2. Důvodem bylo předejít klasickému váhovému rozdělení.

Tabulka 26: Test celkového vzorku pro model X(n2)(d)

Klasifikační matice – test c.v.			
Skupina	Procenta	B = 80 %	A = 20 %
B	82,26 %	19	4
A	72,12 %	75	194

Zdroj: Vlastní zpracování

MODEL₃ byl zařazen do užšího výběru a celkové výsledky, určení šedé zóny a rozbor diskriminační analýzy jsou uvedeny v kapitole č. 5.6. a jejích tabulkách.

5.4.4. Model X(n2)(z)

Model X(n2)(z) představuje zpětnou krokovou analýzu předešlého modelu. Podobně je založený na nejlepších ukazatelých minulých modelů v kombinaci s ukazateli které nebyly nebo neprošli testováním poprvé. Klasifikační funkci modelu X(n2)(d) obsahuje tabulka č. 27. Klasifikační funkce je snížena ze šesti na čtyři proměnné. Nejslabší vážené ukazatele jsou oběžná aktiva dělená krátkodobými zdroji a cizí zdroje dělené součtem čistého zisku a odpisů s váhou 0,01. Naopak nejsilnější váženou proměnnou v modelu znovu představuje podíl peněz a celkovými aktivy s váhou 10,11.

Tabulka 27: Klasifikační funkce pro model X(n2)(z)

Klasifikační funkce			
Proměnné	B = 12 %	A = 88 %	A-B
CZ/(EAT+OD)	-0,01	0,00	0,01
OA/KZ	0,03	0,12	0,10
PK/CA	-0,46	0,55	1,01
PE/CA	2,43	12,54	10,11
Konstanta	-0,95	-1,47	-0,52

Zdroj: Vlastní zpracování

Klasifikační matice testovacího vzorku modelu X(n2)(z) je obsahem tabulky č. 28. Model pomocí vážených proměnných dokázal určit stejně jako vybraní předchůdci 100 % testovacích dat.

Tabulka 28: Test reprezentativního vzorku pro model X(n2)(z)

Klasifikační matice – test t.v.			
Skupina	Procenta	B = 12 %	A = 88 %
B	100 %	6	0
A	100 %	0	43

Zdroj: Vlastní zpracování

Výsledky klasifikační matice spolu s klasifikační funkcí pomohly sestavit výsledný model. Základ tvoří čtyři proměnné a záporná konstanta. Model byl dále otestován na celkovém vzorku.

$\text{MODEL}_4 = -0,493 + 0,01 * \text{CZ}/(\text{EAT} + \text{OD}) + 0,10 * \text{OA}/\text{KZ} + 1,01 * \text{PK}/\text{CA} + 10,11 * \text{PE}/\text{CA}$

kde CZ/(EAT+OD) – cizí kapitál / součet čistého zisku a odpisů majetku, OA/KZ – oběžná aktiva / krátkodobé závazky, PK/CA – pracovní kapitál / celková aktiva, PE/CA – peníze / celková aktiva

Tabulka č.29. obsahuje rozložení bankrotních a aktivních podniků ve sloupcích v kombinaci s realitou v řádcích. Bankrotní podniky nedokázal model oproti dopředné analýze vůbec rozpoznat. Pouze 18 % tj. 3 z 18 podniků, označil korektně. Z aktivních podniků výsledný model dokázal určit téměř 95 %, tedy 380 z celkových 401. Váha bazické proměnné byla určena a znovu testována pomocí aposteriorní pravděpodobnosti s rozdělením váhy bankrotní 0,3 a aktivní pouze 0,7.

Tabulka 29: Test celkového vzorku pro model $X(n2)(z)$

Klasifikační matice – test c.v.			
Skupina	Procenta	B = 30 %	A = 70 %
B	16,66 %	3	15
A	94,76 %	21	380

Zdroj: Vlastní zpracování

MODEL₄ z důvodů slabé přesnosti určení celkového vzorku nebyl zařazen do užšího výběru a tedy i další výsledky, jako je určení šedé zóny nebo rozbor diskriminační funkční analýzy nebudou uvedeny. Celkové hodnocení lze najít v tabulce č. 38.

5.4.5. Model $\log(X(n)+50)(d)$

Model $\log(X(n)+50)(d)$ je prvním logaritmickým modelem založeným na dopředné krokové analýze. Kvůli neřešitelnosti záporného čísla v logaritmické funkci je k hodnotě ukazatele připočítáváno číslo 50. Výsledky jednotlivých ukazatelů jsou logaritmovány, a až poté násobeny váženými koeficienty. Klasifikační funkci modelu $\log(X(n)+50)(d)$ zobrazuje tabulka č. 30. Nějsilnější váženou proměnnou v modelu jsou peníze dělené aktivy 34769 a nejslabším ukazatelem je dlouhodobý hmotný majetek a odpisy 27,93. Konstanta dosahuje obrovské záporné sumy -32501.

Tabulka 30: Klasifikační funkce pro model $(X(n)+50)(d)$

Klasifikační funkce			
Proměnné	B = 75 %	A = 25 %	A-B
DHM/OD	0,70	28,63	27,93
EAT/VK	33,50	1532,69	1499,19
PK/CA	20,24	1175,19	1154,95
KZ/VK	2,30	94,79	92,49
PE/CA	659,93	35428,98	34769,05
Konstanta	-15,55	-32516,52	-32500,97

Zdroj: Vlastní zpracování

Klasifikační matice testovacího vzorku modelu $\log(X(n)+50)(d)$ je obsahem tabulky č. 31. Model pomocí vážených proměnných dokázal určit stejně jako jeho předchůdci 100 % testovacích dat.

Tabulka 31: Test reprezentativního vzorku pro model $(X(n)+50)(d)$

Klasifikační matice			
Skupina	Procenta	B = 75 %	A = 25 %
Bankrotní	100	6	0
Aktivní	100	0	43

Zdroj: Vlastní zpracování

Klasifikační funkce spolu s výsledky klasifikační matice pomohly sestavit výsledný model. Základ tvoří pět proměnných a záporná konstanta. Model byl dále otestován na celkovém vzorku.

$$\text{MODEL}_5 = -32500,97 + 27,93 \cdot \log(\text{DHM}/\text{OD} + 1499,19) \cdot \log(\text{EAT}/\text{VK}) + 1154,95 \cdot \log(\text{PK}/\text{CA}) + 92,49 \cdot \log(\text{KZ}/\text{VK}) + 34769,05 \cdot \log(\text{PE}/\text{CA})$$

kde DHM/OD – dlouhodobý hmotný majetek / odpisy, EAT/VK – čistý zisk / vlastní kapitál, PK/CA – pracovní kapitál / celková aktiva, KZ/VK – krátkodobé závazky / vlastní kapitál, PE/CA – peníze / celková aktiva

Tabulka č.32. obsahuje rozložení bankrotních a aktivních podniků ve sloupcích v kombinaci s realitou v řádcích. Bankrotní podniky dokázal model oproti ostatním daleko lépe rozpoznat. Vynikajících 84,21 % tj. 16 z 19 úpadků, označil korektně. Z aktivních podniků výsledný model dokázal určit nadprůměrných 70,76 %, tedy 276 z celkových 390. Aposteriorní pravděpodobnost byla ohodnocena s rozdělením váhy bankrotní 0,75 a aktivní 0,25 z jedné.

Tabulka 32: Test celkového vzorku pro model $(X(n)+50)(d)$

Klasifikační matice			
Skupina	Procenta	B = 75 %	A = 25 %
B	84,21 %	16	3
A	70,76 %	114	276

Zdroj: Vlastní zpracování

Po aplikaci na celkový vzorek a na předchozí roky, T-2 a T-3 se projevila velká nesoudržnost bankrotních podniků. Nebylo možné určit žádnou výhodnou hranici pro celkový model a tím zlepšit jeho výpovědní schopnost. Výskyt bankrotních podniků byl

až překvapivě rovnoměrný v jednotlivých kvantilech, což znemožnilo jakékoliv kombinace hraničních bodů. Z výše zmíněného důvodu byl tento model zavržen.

5.4.6. Model $\log(X(n)+50)(z)$

Klasifikační funkci modelu $\log(X(n)+50)(z)$ zobrazuje tabulka č. 33. Nějsilnější váženou proměnnou v modelu jsou pracovní kapitál dělený aktivy 616 a podíl peněz na aktivech s váhou 596. Nejslabší vážený ukazatel je čistý zisk dělený nákladovými úroky v hodnotě 3. Konstanta má zápornou hodnotu -2126.

Tabulka 33: Klasifikační funkce pro model $(X(n)+50)(z)$

Klasifikační funkce			
Proměnné	B = 0,371	A = 0,628	A-B
PK/CA	280643	281259	616
EAT/NU	-1387	-1384	3
PE/CA	2466754	2467350	596
TR/OA	62535	62570	35
Konstanta	-2386175	-2388300	-2126

Zdroj: Vlastní zpracování

Klasifikační matice testovacího vzorku modelu $\log(X(n)+50)(z)$ je obsahem tabulky č.34. Model pomocí vážených proměnných dokázal určit stejně jako předchůdci 100 % testovacích dat.

Tabulka 34: Test reprezentativního vzorku pro model $(X(n)+50)(z)$

Klasifikační matice			
Skupina	Procenta	B = 75 %	A = 25 %
Bankrotní	100	6	0
Aktivní	100	0	43

Zdroj: Vlastní zpracování

Klasifikační funkce spolu s výsledky klasifikační matice pomohly sestavit výsledný model. Tvoří jej čtyři proměnné a záporná konstanta. Model byl dále otestován na celkovém vzorku.

$$\text{MODEL}_6 = -2126 + 3 \cdot \log(\text{EAT/NU}) + 616 \cdot \log(\text{PK/CA}) + 596 \cdot \log(\text{PE/CA}) + 35 \cdot \log(\text{TR/OA})$$

kde CZ/(EAT+OD) – cizí kapitál / součet čistého zisku a odpisů majetku, OA/KZ – oběžná aktiva / krátkodobé závazky, PK/CA – pracovní kapitál / celková aktiva, PE/CA – peníze / celková aktiva

Tabulka č.29. obsahuje rozložení bankrotních a aktivních podniků ve sloupcích v kombinaci s realitou v řádcích. Bankrotní podniky nedokázal model oproti dopředné

analýze vůbec rozpoznat. Pouze 18 %, tzn. 3 z 18 podniků, označil korektně. Z aktivních podniků výsledný model dokázal určit téměř 95 %, tedy 380 z celkových 401. Váha bazické proměnné byla určena a znovu testována pomocí aposteriorní pravděpodobnosti s rozdělením váhy bankrotní 0,3 a aktivní pouze 0,7.

Tabulka 35: Test celkového vzorku pro model $(X(n)+50)(z)$

Klasifikační matice			
Skupina	Procenta	B = 80	A = 20
B	92,85	13	1
A	72,02	80	206

Zdroj: Vlastní zpracování

MODEL₅ byl vyhodnocen jako velmi přesný a zařazen do užšího výběru. Celkové výsledky, určení šedé zóny a rozbor diskriminační analýzy jsou uvedeny v kapitole č. 5.7. a jejích tabulkách.

5.5. Porovnání vytvořených modelů

Tato podkapitola pojednává porovnání vytvořených modelů. Cílem je vytvořit přehled o správně a špatně zařazených podnicích a ohodnocení přesnosti modelů. Bodové hodnocení modelů je naprosto totožné s hodnocením vybraných modelů z předešlé kapitoly 4.4.6. Každý model dostane záporné body za falešný poplach, přehlédnutou hrozbu a aplikovatelnost na data.

Tabulka č. 36. obsahuje informace o správně zařazených podnicích vypočtených modelů. V prvním sloupci jsou názvy jednotlivých modelů korepondující s kapitolou 5.4. Druhý sloupec je přesnost určení aktivních podniků. Nejlepším modelem je MODEL₁, který dokázal určit 99 %. Predikci bankrotu naopak kraluje model MODEL₆ se 93 % úspěšností. Tento model je zároveň i nejlepším model, který byl vytvořen.

Tabulka 36: Správně zařazené podniky vytvořených modelů v čase T-1

Modely	Aktivní			Bankrotní			Celkem podniků
	Číslo	Procento	Celkem A,	Číslo	Procento	Celkem B,	
MODEL ₁	355	99	357	2	14	14	371
MODEL ₂	420	98	428	4	18	22	450
MODEL ₃	194	72	269	19	82	23	293
MODEL ₄	380	95	401	3	17	18	419
MODEL ₅	276	71	390	16	84	19	409
MODEL ₆	206	72	286	13	93	14	300

Zdroj: Vlastní zpracování

Výčet chybně zařazených podniků naopak obsahuje tabulka č. 37. Jde o inverzní hodnocení oproti tabulce č. 36. V tomto směru byl nejhorším modelem pro určení úpadku MODEL₁, který vyhodnotil 86 % bankrotních podniků jako aktivní. Tesně za ním dopadly modely MODEL₂ a MODEL₄. Falešný poplach nejvíce zaznamenaly modely MODEL₅ a MODEL₃, každý okolo 30 %.

Tabulka 37: Chybně zařazené podniky vytvořených modelů v čase T-1

Modely	Aktivní			Bankrotní			Celkem podniků
	Číslo	Procento	Celkem A,	Číslo	Procento	Celkem B,	
MODEL ₁	2	1	357	12	86	14	371
MODEL ₂	8	2	428	18	82	22	450
MODEL ₃	75	28	269	4	17	23	293
MODEL ₄	21	5	401	15	83	18	419
MODEL ₅	114	29	390	3	16	19	409
MODEL ₆	80	28	286	1	7	14	300

Zdroj: Vlastní zpracování

Komplexní ohodnocení vytvořených modelů obsahuje tabulka č. 38. V prvním sloupci tvoří hodnocení neúspěšnosti určení aktivního podniku, druhým je hodnocení neúspěšnosti predikce bankrotu a posledním kritériem je hodnocení aplikovatelnosti modelu na vzorek dat. Jednotlivé hodnocení je stejné jako v kapitole 4.4.6., bylo stanoveno 1 bod za falešný poplach, 5 bodů za hrozbu a aplikovatelnost dat za 0,5 bodů. Hodnocení spočívá v opačné stupnici, tedy čím více bodů model dostane, tím je horší. Nejlepším vybraným modelem je logaritmický MODEL₆ se 82 body. Na druhém místě se umístil relativně přesně nelogaritmický MODEL₃ a logaritmický MODEL₅ oba se 115 zápornými body. Další modely dostaly takový počet záporných bodů, že jedinou záchranou by pro ně byla extrémní šedá zóna.

Tabulka 38: Bodové hodnocení vytvořených modelů v čase T-1

Modely	Body (Za falešný poplach 1b)	%	Body (Za přehlédnutou hrozbu 5b)	%	Aplikovatelnost na data (0,5b)	%	Body celkem
MODEL ₁	1	1	429	86	11	78	441
MODEL ₂	2	2	409	82	3	95	414
MODEL₃	28	28	86	17	19	62	115
MODEL ₄	5	5	417	83	6	88	428
MODEL ₅	29	29	79	16	7	86	115
MODEL₆	28	28	36	7	18	63	82

Zdroj: Vlastní zpracování

Na základě těchto výsledků byl vybrán jeden logaritmický a jeden nelogaritmický model. Z předešlé tabulky jde o MODEL₆ a MODEL₃. Modely budou více testovány pro určení šedé zóny a detailnějšího rozboru diskriminační funkční analýzy.

5.6. MODEL₃ - X(n2)(d)

V této podkapitole je detailněji popsána tvorbu modelu X(n2)(d), který nejen určil 100 % testovacích dat, ale v hodnocení modelů vyšel jako vůbec nejlepší nelogaritmický model. K modelu bude přiřazena šedá zóna a bude testován na časových datech T, T-2, T-3 a T-4, aby mohl být porovnán s vybranými bankrotními modely.

Tabulka č. 39. obsahuje výsledky diskriminační funkční analýzy. P hodnota jasně ukazuje, že první čtyři proměnné jsou velmi významné v modelu a mají největší podíl na přesnosti. Ukazatelé NZ/CA a EAT/VK dopadly na hraně přijatelné hodnoty a v modelu mají rozhodnou funkci až v obdobích T-3 a T-4. Nejlepší toleranci získala proměnná NZ/CA. Má velmi unikátní variabilitu a je nevysvětlená ostatními proměnnými v modelu. Univerzální příspěvky proměnných – parciální lambda má nejlepší ukazatel PK/CA o hodnotě 0,8539. Celková Wilkssova lambda modelu je 0,7131. V prvním sloupci lze najít wilkslambda celého modelu při vyřazení dané proměnné.

Tabulka 39: Výsledky diskriminační funkční analýzy pro model X(n2)(d)

Výsledky diskriminační funkční analýzy						
Proměnné	W. lambda	Parc. lambda	F. na vyj (1.17)	p. hodnota	Tolerance	1 – toler. R ²
CZ/(EAT+OD)	0,728178	0,979300	10,80113	0,001084	0,993838	0,006162
EAT/VK	0,746360	0,955444	23,82995	0,000001	0,969404	0,030596
PK/CA	0,835075	0,853942	87,40165	0,000000	0,846061	0,153939
PE/CA	0,802240	0,888892	63,87293	0,000000	0,834236	0,165764
NZ/CA	0,725838	0,995418	2,347478	0,126106	0,293582	0,706419
EAT/VK	0,719645	0,995147	2,486921	0,115416	0,998767	0,001233

Zdroj: Vlastní zpracování

Jednotlivé procentní příspěvky proměnných do Modelu X(n2)(d) tvoří tabulku č. 41. Největší příspěvek 35,79 %, má ukazatel cizí zdroje dělený sumou čistého zisku a odpisů. Na druhém místě s 23,28 % je čistý zisk dělený vlastním kapitálem. Třetí a čtvrté místo s průměrnými 15 % patří podílu pracovního kapitálu ku celkovým aktivům a penězům ku celkovým aktivům. Poslední příčky obsadily proměnné jako nerozdělený zisk dělený celkovými aktivy a čistý zisk dělený vlastním kapitálem.

Tabulka 40: Procentní příspěvek proměnných do modelu

Proměnné	Výpočet % příspěvku založený na F - hodnotě
CZ/(EAT+OD)	35,79
EAT/VK	23,28
PK/CA	17,01
PE/CA	13,04
NZ/CA	6,03
EAT/VK	4,28

Zdroj: Vlastní zpracování

Klasifikační funkci a matice přesnosti lze nalézt v tabulkách č. 24, č. 25, a č. 26. Jak již bylo zmíněno v předešlé kapitole 5.4.3. toto je výsledný vzorec modelu:

$$\text{MODEL}_3 = -0,493 + 0,005 * \text{CZ}/(\text{EAT} + \text{OD}) + 0,015 * \text{EAT}/\text{VK} + 0,099 * \text{OA}/\text{KZ} + 0,739 * \text{PK}/\text{CA} + 9,918 * \text{PE}/\text{CA} + 0,149 * \text{NZ}/\text{CA}$$

Šedá zóna pro X(n2)(d)

Pro výpočet šedé zóny modelu byla použita jednoduchá strategie. Rozdělení chybně zařazených podniků do zón a dle zóny s největším počtem chyb stanovit hranice. Vlastní interpretaci rozdělení do zón osahuje tento vzorec:

$$\text{Zóna} = F_{i(B)} \vee F_{i(A)} \max > (\text{HH} + \text{DH}) / n$$

$$(11,05 - (-11,68)) / 8 = 2,525$$

kde $F_{i(B)}$ je četnost bankrotní podniků, $F_{i(A)}$ je četnost podniků aktivních, n je počet zón, HH – horní hranice, DH – dolní hranice

Tabulka 41: Rozdělení chybně označených podniků

Zóny	HH	DH	Chybně označené	
			A	B
1	-11,675	-9,15	0	0
2	-9,15	-6,625	1	0
3	-6,625	-4,1	0	0
4	-4,1	-1,575	2	0
5	-1,575	0,95	72	4
6	0,95	3,475	0	0

7	3,475	6	0	0
8	6	8,525	0	0
9	8,525	11,05	0	0

Zdroj: Vlastní zpracování

Na základě tabulky č. 41. byla určena šedá zóna modelu s dolní hranicí -0,3 a horní hranicí v čísle nula. Zóna pokryla 2 bankrotní podniky a 67 aktivních, které byly špatně zařazeny. Existuje ještě druhá varianta s odlišnými hranacemi a lepším bodovým ziskem, ale celková přesnost modelu je daleko menší. Tabulka č. 42. obsahuje hranice šedé zóny a do ní zařazené aktivní i bankrotní podniky po její aplikaci.

Tabulka 42: Šedá zóna modelu v čase T-1

	Šedá zóna		Aktivní		Bankrotní	
Var.	HH	DH	Model	Celkem	Model	Celkem
Var. 2	0	-0,3	67	312	2	15
Var. 1	-0,15	-0,2	31	312	3	15

Zdroj: Vlastní zpracování

Hranice, které dělí bankrotní a aktivní podniky, dávají modelu daleko větší přesnost. Podle výsledku MODEL₃₂ je společnost klasifikována do jednoho ze tří pásem: do aktivní zóny, bankrotní zóny a nebo šedé zóny, Toto rozdělení ohraničují tyto intervaly:

- $Z > 0$ → Aktivní zóna – společnost je finančně stabilní
- $Z = (0 ; -0,3)$ → Šedá zóna – nestabilní společnost nebo model nedokáže určit
- $Z < -0,3$ → Bankrotní zóna – společnost má velké finanční potíže

Tabulka č. 43 porovnává MODEL₃ bez šedé zóny a po její aplikaci vznikají MODEL₃₁ a MODEL₃₂, které jsou podle bodového hodnocení ještě lepší. Záporné body za falešný poplach se u MODEL₃₁ sníží na polovinu a za přehlédnutou hrozbu dokonce o 55 bodů na 31. Po celkovém součtu se model zlepšil z 115 na 65 bodů. MODEL₃₂ je sice menší zlepšení, ale zato jeho celková přesnost je vyšší.

Tabulka 43: Rozdíl bodového hodnocení s šedou zónou

Modely	Body (Za falešný poplach 1b)	%	Body (Za přehlédnutou hrozbu 5b)	%	Aplikovatelnost na data (0,5b)	%	Body celkem
MODEL ₃₂	9	9	77	15	19	62	105
MODEL₃₁	15	14,5	31	6,25	19	62	65
MODEL ₃	28	28	86	17	19	62	115

Zdroj: Vlastní zpracování

Aplikace $MODEL_{32}$ na všechna časová období popisuje tabulka č. 44. Pro model je charakteristická přesnost určení aktivních podniků přes 90 % a pro predikci bankrotu stoupající přesnost s velkou odchylkou v čase T-1. Nejlepších výsledků dosahuje model v období T-1, kdy je jeho celková přesnost 77,02 %. Na rozdíl od ostatních modelů má slušný odhad aktivních i bankrotních podniků a tudíž je i přesnější.

Tabulka 44: Vlastnosti modelu s šedou zónou na vzorku dat a jeho přesnost

$MODEL_{32}$	T	T-1	T-2	T-3	T-4
Správně A.	302	284	335	298	269
Špatně A.	28	28	33	31	22
Správně B.	6	11	11	8	5
Špatně B.	2	2	4	2	4
Šedá zóna	68	69	59	57	50
Přesnost A.	91.52	91.03	91.03	90.58	92.44
Přesnost B.	75.00	84.62	73.33	80.00	55.56
Celková přesnost	68.64	77.02	66.76	72.46	51.36

Zdroj: Vlastní zpracování

5.7. $MODEL_6 - \log(X(n)+50)(z)$

V této podkapitole je popsán druhý model, který získal dobré bodové ohodnocení. Model $\log(X(n)+50)(z)$, který podobně jako jeho protějšek nejen určil 100 % testovacích dat, ale v hodnocení modelů vyšel jako vůbec nejlepší model. K modelu bude přiřazen popis šedé zóny a bude obdobně testován na časových datech T, T-2, T-3 a T-4, aby mohl být porovnán s vybranými bankrotními modely.

Tabulka č. 45. obsahuje výsledky diskriminační funkční analýzy. P hodnota jasně ukazuje, že první dvě proměnné jsou velmi významné v modelu a mají největší podíl na přesnosti. Nejlepší toleranci získala proměnná PE/CA. V prvním sloupci lze najít wilkslambda celého modelu při vyřazení dané proměnné. Univerzální příspěvky proměnných – pasciální lambda má nejlepší ukazatel PK/CA o hodnotě 0,885. Celková Wilkssova lambda modelu je 0,83256.

Tabulka 45: Výsledky diskriminační funkční analýzy pro model $\log(X(n)+50)(z)$

Výsledky diskriminační funkční analýzy						
Proměnné	W. lambda	Parc. lambda	F. na vyj (1,17)	p. hodnota	Tolerance	1 – toler. R ²
PK/CA	0,955668	0,88547	37,1214	0,000000	0,965168	0,034832
EAT/NU	0,868245	0,97462	7,47128	0,006658	0,971794	0,028206
PE/CA	0,854088	0,99078	2,66989	0,103360	0,949836	0,050164
TR/OA	0,849483	0,99615	1,10799	0,293405	0,953640	0,046360

Zdroj: Vlastní zpracování

Jednotlivé procentní příspěvky proměnných do modelu $\log(X(n)+50)(z)$ tvoří tabulku č. 46. Největší příspěvek 39,72 %, má ukazatel pracovní kapitál dělený celkovými aktivy. Na druhém místě s 25,38 % je podíl čistého zisku a nákladových úroků. Třetí a čtvrté místo s průměrnými 15,5 % patří podílu peněz ku celkovým aktivům a tržbám děleným oběžnými aktivy.

Tabulka 46: Procentní příspěvek proměnných do modelu

Proměnné	Výpočet % příspěvku založený na F - hodnotě
PK/CA	39,72
EAT/NU	25,38
PE/CA	18,01
TR/OA	13,04

Zdroj: Vlastní zpracování

Klasifikační funkci a matice přesnosti lze nalézt v tabulkách č. 30., č. 31. a č. 32. Jak již bylo zmíněno v předešlé kapitole 5.4.6. toto je výsledný vzorec modelu:

$$\text{MODEL}_6 = -2126 + 3 \cdot \text{EAT/NU} + 616 \cdot \text{PK/CA} + 596 \cdot \text{PE/CA} + 35 \cdot \text{TR/OA}$$

Šedá zóna pro model $\log(X(n)+50)(z)$

$$Zóna = F_{i(B)} \vee F_{i(A)} \max > (HH+DH) / n$$

$$(6,9 - (-9,37)) / 8 = 2,5525$$

kde $F_{i(B)}$ je četnost bankrotní podniků, $F_{i(A)}$ je četnost podniků aktivních, n je počet zón, HH – horní hranice, DH – dolní hranice

Tabulka 47: Rozdělení chybně označených podniků

Zóny	HH	DH	Chybně označené	
			A	B
1	-9,37	-6,8175	0	0
2	-6,8175	-4,265	0	0
3	-4,265	-1,7125	8	0
4	-1,7125	0,84	72	0
5	0,84	3,3925	0	1
6	3,3925	5,945	0	0
7	5,945	8,4975	0	0
8	8,4975	11,05	0	0

Zdroj: Vlastní zpracování

Na základě tabulky č. 47 byla určena šedá zóna modelu s dolní hranicí -0,1 a horní hranicí v čísle 0,75. Zóna pokryla 2 bankrotní podniky a 67 aktivních, které byly špatně zařazeny. Tabulka č. 48. obsahuje hranice šedé zóny a do ní zařazené aktivní i bankrotní podniky po její aplikaci.

Tabulka 48: Šedá zóna modelu v čase T-1

Šedá zóna		Aktivní			Bankrotní		
HH	DH	Model	Celkem	%	Model	Celkem	%
0,75	-0,1	88	233	37,6	0	16	0

Zdroj: Vlastní zpracování

Hranice, které dělí bankrotní a aktivní podniky dávají modelu daleko větší přesnost. Podle výsledku $MODEL_{52}$ je společnost klasifikována do jednoho ze tří pásem: do aktivní zóny, bankrotní zóny a nebo šedé zóny, Toto rozdělení ohraničují tyto intervaly:

- $Z > -0,1$ → Aktivní zóna – společnost je finančně stabilní
- $Z = (-0,1 ; 0,75)$ → Šedá zóna – nestabilní společnost nebo model nedokáže určit
- $Z < 0,75$ → Bankrotní zóna – společnost má velké finanční potíže

Tabulka č. 49 porovnává $MODEL_6$ bez šedé zóny a po její aplikaci vznikající $MODEL_{61}$. Ačkoliv aplikace šedé zóny pomůže snížit procento bankrotních podniků ohodnocených špatně, zároveň zvýší procento falešných poplachů. Konečným výsledkem je pak stejný počet bodů, ale jinak rozpoložená přesnost.

Tabulka 49: Rozdíl bodového hodnocení s šedou zónou

Modely	Body (Za falešný poplach 1b)	%	Body (Za přehlédnutou hrozbu 5b)	%	Aplikovatelnost na data (0,5b)	%	Body celkem
MODEL₆₁	33	32,6	31	6,25	18	38	82
MODEL₆	28	28	36	7	18	63	82

Zdroj: Vlastní zpracování

Aplikace MODEL_{U32} na všechna časová období popisuje tabulka č. 50. Pro model je charakteristická konstantní přesnost 66 % u aktivních podniků a rostoucí procento určení úpadku firmy během jednotlivých let. Nejlepších výsledků dosahuje model v období T-1, kdy je jeho celková přesnost 62,89 %.

Tabulka 50: Vlastnosti modelu s šedou zónou na vzorku dat a jeho přesnost

MODEL₆₁	T	T-1	T-2	T-3	T-4
Správně A.	158	157	140	132	112
Správně B.	7	14	8	8	7
Špatně A.	79	76	74	66	55
Špatně B.	1	1	2	3	2
Šedá zóna	1	0	0	3	1
Přesnost A.	66,67	67,38	65,42	66,67	67,07
Přesnost B.	87,50	93,33	80,00	72,73	77,78
Celková přesnost	58,33	62,89	52,34	48,48	52,16

Zdroj: Vlastní zpracování

6. SROVNÁNÍ EFEKTIVNOSTI VYTVOŘENÝCH A VYBRANÝCH MODELŮ

Poslední kapitola je věnována porovnání efektivnosti vytvořených modelů s vybranými modely. Jde o stejný typ porovnání jako v přechozích kapitolách. Cílem je nejen ohodnotit a porovnat všechny modely v práci, ale i na základě celkové přesnosti vybrat nejpoužitelnější vytvořený model. Dílčím cílem je popis uplatnění jednotlivých vytvořených modelů. Pro komplexní hodnocení je potřeba sestavit tabulky pro chybně zařazené podniky, určení bankrotu podle jednotlivých modelů na časových úsecích a celkové přesnosti jednotlivých modelů na časových úsecích.

Bodové porovnání vybraných a vytvořených modelů je obsažené v tabulce č. 51. Hodnocení je stejné jako v předešlých kapitolách. Nejlepším modelem dle tohoto hodnocení zůstává Altmanovo Z skóre z roku 1983. Velmi mu pomáhá jeho aplikovatelnost a přesnost predikce úpadku.

Tabulka 51: Chybně zařazené podniky vytvořených a vybraných modelů v čase T-1

Modely	Body (Za falešný poplach 1b)	%	Body (Za přehlédnutou hrozbu 5b)	%	Aplikovatelnost na data (0,5b)	%	Body celkem
MODEL ₃₁	15	14,5	31	6,25	19	38	65
MODEL ₃₂	9	9	77	15	19	62	105
MODEL ₆₁	33	32,6	31	6,25	18	38	82
Z skóre 83	33	33	23	5	1	3	57
AS log	37	37	0	0	22	44	59
Z skóre 77	40	40	21	4	1	2	62
IN 05	32	32	146	29	1	2	179
AS nlog	7	7	294	59	17	34	318

Zdroj: Vlastní zpracování

Vybrané modely oproti modelům vytvořeným disponují až na výjimky daleko větší přesností predikce bankrotu. Důvodem je, že tyto modely jsou dost přísné a velké procento aktivních podniků pak zůstává v šedé zóně nebo je označeno jako falešný poplach. Nejlepší modely dle tohoto hodnocení jsou logaritmický Altman Sabato model a Altmanovo Z skóre z roku 1977. Oba dosahují hranice 100 % v rozdílných časových úsecích. Na posledním místě je naopak Altman Sabato model, který v nejlepším případě obdržel 53 % přesnost. Vytvořené bankrotní modely dopadly velmi průměrně, většinou kolem hranice 50-70 % pro T-4 až po 75-87 % v době bankrotu.

Tabulka 52: Predikce bankrotu na časových úsecích za jednotlivých modelů

Model / Období	T	T-1	T-2	T-3	T-4
MODEL ₆₁	87,50	93,33	80,00	72,73	77,78
MODEL ₃₂	76,92	93,75	70,59	64,71	50,00
MODEL ₃₁	75,00	84,62	73,33	80,00	55,56
AS log	100,0	100,0	83,3	83,3	66,7
AS	16,7	41,2	53,3	35,7	38,5
Z skóre 77	95,2	95,5	94,7	94,7	100,0
Z skóre 83	94,7	95,0	94,7	94,4	100,0
IN 05	85,0	69,6	71,4	66,7	76,5

Zdroj: Vlastní zpracování

Pro hodnocení modelů je důležité ještě jedno hledisko. Celková přesnost je základním kamenem každého modelu. Modely mohou mít velkou úspěšnost predikce bankrotu nebo naopak jsou velmi přesné v rozlišení falešného poplachu. Pouze některé modely jsou však univerzální a dokáží určit značnou část aktivních i bankrotních podniků. Výpočet celkové přesnosti je snadný. Jde o součin procentuelních úspěšností, jak bankrotních tak aktivních. V tabulce č. 53. je právě takový výpočet pro vybrané a vytvořené modely ve všech časových obdobích. Nejlepším modelem s třemi nejvyššími přesnostmi je MODEL₃₂. V čase bankrotu a v šase dva a tři roky před bankrotem, dokázal určit úctihodných 66 až 72 % veškerých podniků. Na druhém místě je MODEL₃₁ s velmi podobnými výsledky a dokonce v čase T-1 se 78,24 % přesností. V čase T-4 je MODEL₆₁ nepřesnějším ze všech. Jeho 52,16 % úspěšnost není nějak průlomová, ale na druhou stranu, oproti nejhoršímu modelu má přes 20 % náskok. Vybrané modely v tomto hodnocení dosáhly spíše průměrných přesností. Nejlepším vybraným modelem je logaritmický Altman Sabato model. S rostoucí přesností od času T-4 41,2 % až po 62,8 % v době bankrotu. Celkově nejhorším modelem je nelogaritmovaný Altman Sabato model. V kritické části dosáhl pouze 15 % přesnosti.

Tabulka 53: Celková přesnost na časových úsecích jednotlivých modelů

Model / Období	T	T-1	T-2	T-3	T-4
MODEL ₆₁	58,33	62,89	52,34	48,48	52,16
MODEL ₃₁	67,92	78,24	61,76	56,81	45,26
MODEL₃₂	68,64	77,02	66,76	72,46	51,36
AS log	62,8	63,0	54,4	52,3	41,2
AS	15,1	38,3	48,3	31,8	33,1
Z skóre 77	46,1	48,1	46,5	45,2	44,1
Z skóre 83	44,6	46,3	43,4	42,1	41,3
IN 05	47,9	40,2	39,0	33,6	33,2

Zdroj: Vlastní zpracování

Po shrnutí veškerých hodnocení a faktorů byl jako výsledný model vybrán MODEL₃₂ - **Model X(n2)(d)**. Nejenže dosáhl vynikajících výsledků při rozlišení bankrotních a aktivních podniků, ale dokázal si tuto vlastnost podržet i při testování na časových úsecích.

$$\text{MODEL}_3 = -0,493 + 0,005 * CZ/(EAT+OD) + 0,015 * EAT/VK + 0,099 * OA/KZ + 0,739 * PK/CA + 9,918 * PE/CA + 0,149 * NZ/CA$$

a šedá zóna:

- $Z > 0$ → Aktivní zóna – společnost je finančně stabilní
- $Z = (0 ; -0,3)$ → Šedá zóna – nestabilní společnost nebo model nedokáže určit
- $Z < -0,3$ → Bankrotní zóna – společnost má velké finanční potíže

Na závěr kapitoly je nutné shrnout informace pro odpovědi na vědecké otázky z první kapitoly:

- Jsou vybrané modely přesnější v určení bankrotních podniků než vytvořené modely – odpověď – ANO
- Jsou vybrané modely přesnější v určení aktivních a bankrotních podniků než vytvořené modely – odpověď – NE

Dle tabulek této kapitoly je zřejmé, že vybrané bankrotní modely dostačují na určení jakékoliv bankrotní zemědělské firmy. Jejich jedinou nevýhodou je, že při jejich tvrdém hodnocení ocení i mnoho zdravých podniků špatně. Vytvořené modely sice nedisponují tak velkou přesností hrozícího úpadku, ale na druhou stranu dokáží objektivněji posoudit daleko větší procento podniků.

ZÁVĚR

Bankrotní modely jsou součástí hlubší finanční analýzy podniku. Jejich cílem je ohodnotit finanční zdraví podniku a predikovat možný úpadek pomocí vybraných ukazatelů. Jejich počátek se datuje k 60. letům minulého století. Od této doby bylo vytvořeno nespočet modelů pro různé země, odvětví a typy podniků.

Tato diplomová práce se snaží přinést nové poznatky do predikce bankrotu, tvorby modelů a jejich hodnocení v rámci českého zemědělství. Odvětví zemědělství je z pohledu přínosu pro HDP jedno z nejslabších na našem území. Přesto je však základním kamenem pro každého občana. Cílem práce bylo tedy zhodnotit vybrané modely a jejich přesnost ve výše zmíněném odvětví a popřípadě vytvořit přesnější model.

Během testování modelů bylo zjištěno, že vybrané modely nedosahují dostatečných výsledků v celkovém ohodnocení vzorku dat. I přesto, že jejich přesnost úpadku je vysoká, modely zároveň označí většinu zdravých firem za bankrotní. Z toho důvodu byl podán návrh na odvození nových modelů, které by disponovaly velkou přesností na současných datech zemědělských podniků. Podobně jako autoři v minulosti, byly zkoumány různé přístupy tvorby modelů. Jediným problémem bylo určení ukazatelů podniku, které by významně přispěly k celkové přesnosti. Po posouzení možností bylo rozhodnuto pro využití metod parametrického přístupu tvorby. Pomocí lineární diskriminační analýzy bylo sestaveno šest nových modelů, z nich dva dosahovaly požadovaných hodnot. Pro zlepšení těchto modelů, byly využity modely přístupu určení šedé zóny. Díky těmto úpravám vzrostla přesnost některých modelů o několik procent. Výsledkem práce je tedy porovnání vybraných modelů a vytvoření modelu Model X(n2)(d), který disponuje daleko lepší přesností.

SEZNAM POUŽITÝCH ZDROJŮ

- [1] ALTMAN, E. I., *Corporate financial distress: A complete guide to predicting, avoiding and dealing with bankruptcy*. New York: John Wiley and Sons. 1983. ISBN 978-0-471-69189-1
- [2] ALTMAN, E. I. and G. SABATO. Modelling Credit Risk for SMEs: Evidence from the U.S. Market. *Abacus*. 2007, vol. 43, no. 3, str. 332-357. ISSN 0001-3072.
- [3] ALTMAN, E. I. The Success of Business Failure Prediction Models: An International Survey *Journal of Banking and Finance*, 8, 1984, str.171-198.
- [4] BANSAL, P., SALLING J., *Adaptive Regression Splines (MARS)*, [online]. 2013, [cit. 2017-05-23]. Dostupné z: www.lans.ece.utexas.edu/courses/ee380l_ese/2013/mars.pdf
- [5] BEAVER, William H, Financial Ratios As Predictors of Failure, *Journal of Accounting Research*, 1966, 4, 71-, DOI: 10.2307/2490171, ISSN 00218456, Dostupné také z: <http://www.jstor.org/stable/10,2307/2490171?origin=crossref>
- [6] BIELIKOVÁ, T., T. BÁNYIOVÁ and A. PITERKOVÁ. Prediction Techniques of Agriculture Enterprises Failure. *Procedia Economics and Finance*. 2014, vol. 12, s. 48-56. ISSN 2212-5671.
- [7] FRIEDMAN, JEROME H. Multivariate Adaptive Regression Splines. *Ann. Statist.* 19 (1991), no. 1, 1--67. doi:10.1214/aos/1176347963. Dostupné z: <http://projecteuclid.org/euclid.aos/1176347963>.
- [8] GRICE, J. S. and M. T. DUGAN. The limitations of bankruptcy prediction models: Some cautions for the researchers. *Review of Quantitative Finance and Accounting*. 2001, vol. 17, no. 2, s. 151-166. ISSN 1573-7179.
- [9] HEBÁK, PETR, Srovnání klasické a bayesovské pravděpodobnosti a statistiky (1.), In: *ACTA OECONOMICA PRAGENSIA*, Praha: VŠE, 2012, 69-87, Dostupné z: <http://www.vse.cz/aop/abstrakt.php3?IDcl=359>
- [10] HŘEBÍČEK, J, ŠKRDLA, M., 2006. *Úvod do matematického modelování*. [online]. [cit. 2017-5-06]. Dostupné z: <http://is.muni.cz/el/1431/podzim2007/bi3101/um/skripta.pdf>
- [11] JAKROVSKÝ J., LITTNEROVÁ S., Vícerozměrné statistické metody: Diskriminační analýza. *Iba.mumi: VÍCEBOROVÁ INOVACE STUDIA MATEMATICKÉ BIOLOGIE* [online]. Brno, 2009 [cit. 2017-05-24]. Dostupné z:

<http://www.iba.muni.cz/esf/res/file/bimat-prednasky/vicerozmerne-statisticke-metody/VSM-08.pdf>

- [12] KARAS, Michal. *Měření úvěrového rizika podniků zpracovatelského průmyslu v České republice* [online]. Vysoké učení technické v Brně. Fakulta podnikatelská, 2013 [cit. 2017-05-23]. Dostupné z: <http://hdl.handle.net/11012/27538>. Disertační práce.
- [13] KARAS, M., REŽŇÁKOVÁ, M. Creating a new bankruptcy prediction model: The grey zone problem. DOI: 10.13140/2.1.1450.7208 Dostupné z: https://www.researchgate.net/publication/267874369_Creating_a_new_bankruptcy_prediction_model_The_grey_zone_problem.
- [14] KISLINGEROVÁ, Eva. *Finanční analýza: krok za krokem*. Praha: C.H. Beck, 2005. C.H. Beck pro praxi. ISBN 80-7179-321-3. Ing. Josef Mrkvička: Finanční analýza, Bilance, Praha, 1997
- [15] KOVANICOVÁ, Dana a Pavel KOVANIC. *Poklady skryté v účetnictví*. 4. aktualiz. vyd. Praha: Polygon, 1999. ISBN 80-85967-88-x. Polygon, Praha, 1999
- [16] LUKASON, O. Why and how agricultural firms fail: evidence from Estonia. *Bulgarian Journal of Agricultural Science*. 2014, vol. 20, no. 1, s. 5-11. ISSN 1310-0351
- [17] LUŇÁČEK, J. Selection of Bankruptcy Prediction Model for the Construction Industry - A Case Study from the Czech Republic. *Proceedings of The 25th International Business Information Management Association Conference*. Amsterdam, 2015. str 2627-2638. ISBN 978-0-9860419-4-5
- [18] NEUMAIEROVA, I. a I. NEUMAIER. Index IN05. In: ČERVINEK, P. (ed.). *Evropské finanční systémy*. Brno: Masarykova univerzita, 2005. str.143-148. ISBN 80-210-3753-9.
- [19] REŽŇÁKOVÁ, M. a kol. *Řízení platební schopnosti podniku*, Grada Publishing. 2010. ISBN 978-80-247-3441-5
- [20] RŮČKOVÁ, Petra. *Finanční analýza: metody, ukazatele, využití v praxi*. 5., aktualizované vydání. Praha: Grada Publishing, 2015. Finanční řízení. ISBN 978-80-247-5534-2.
- [21] SEDLÁČEK, Jaroslav. *Finanční analýza podniku*. 2., aktualiz. vyd. Brno: Computer Press, 2011. ISBN 978-80-251-3386-6.

- [22] SUŠICKÝ, JAN. Využitelnost bankrotních modelů a jejich aplikace v podmínkách České republiky. Česká zemědělská univerzita v Praze. Praha, 2011.
- [23] TAFFLER, R. J. Forecasting company failure in the UK using discriminant analysis and financial ratio data. *Journal of the Royal Statistical Society*. 1982, vol. 145, pp. 342–358. ISSN 1467-9868
- [24] VALACH, Josef. *Finanční řízení podniku*. 2. aktualiz. a rozš. vyd. Praha: Ekopress, 1999. ISBN 80-86119-21-1.
- [25] VOCHOZKA, Marek. *Metody komplexního hodnocení podniku*. Praha: Grada, 2011. Finanční řízení. ISBN 978-80-247-3647-1. Miroslav Synek a kolektiv: Manažerská ekonomika, ISBN 80-247-0515-X,

SEZNAM POUŽITÝCH ZKRATEK

MDA	Vícenásobná diskriminační analýza,
LDA	Lineární diskriminační analýza,
ID3	(Iterative Dichotomiser 3) – nadstavba klasických rozhodovacích stromů,
SOM	Samoorganizující síť,
BPNN	Umělá neuronová síť se zpětným šířením (Back Propagation Neural Network),
MLP NN	Vícevrstvá perceptronová neuronová síť (Multi Layer Perception Neural Network),
EBIT	Zisk před zdaněním, nákladovými úroky odpisy- (Earnings Before Interest, Taxes),
EBITDA	Zisk před zdaněním, nákladovými úroky a odpisy (Earnings Before Interest, Taxes, Depreciation and Amortazation),
EAT	Zisk po zdanění (Earnings After Taxes),
EBT	Zisk před zdaněním (Earnings Before Taxes),
MARS	Vícerozměrné adaptivní regresivní křivky (Multivariate Adaptive Regression Splines),
T.V.	Testovací vzorek,
C.V.	Celkový vzorek,

SEZNAM OBRÁZKŮ

Obrázek 1: Lineární regrese	17
Obrázek 2: MARS regrese	25
Obrázek 3: Příklad neuronové sítě	26
Obrázek 4: Koncept šedé zóny.....	27
Obrázek 5: ROC křivka modelu IN 05	47
Obrázek 6: ROC křivka modelu Z skóre 77	49
Obrázek 7: ROC křivka modelu Z skóre 83	51
Obrázek 8: ROC křivka modelu Altman Sabato.....	53
Obrázek 9: ROC křivka modelu Altman Sabato logaritmický	55

SEZNAM GRAFŮ

Graf 1: Rozdělení celkového vzorku	45
Graf 2: Úspěšnost predikce aktivních podniků v čase T-1	56
Graf 3: Úspěšnost predikce bankrotních podniků v čase T-1	57
Graf 4: Podniky zařazené do šedé zóny v čase T-1	57

SEZNAM TABULEK

Tabulka 1: Přesnost Altmanova Z skóre	33
Tabulka 2: Výběr proměnných modelu	39
Tabulka 3: Rozdělení podniků dle počtu pracovníků a aktiv.....	44
Tabulka 4: IN 05 – rozložení podniků v T-1	46
Tabulka 5: Vlastnosti modelu IN 05 na vzorku dat a jeho přesnost	47
Tabulka 6: Z skóre 77 – rozložení podniků v T-1.....	48
Tabulka 7: Vlastnosti modelu Z skóre 77 na vzorku dat a jeho přesnost	49
Tabulka 8: Z skóre 83 – rozložení podniků v T-1.....	50
Tabulka 9: Vlastnosti modelu Z skóre 83 na vzorku dat a jeho přesnost	51
Tabulka 10: Altman Sabato model – rozložení podniků v T-1	52
Tabulka 11: Vlastnosti modelu Altman Sabato na vzorku dat a jeho přesnost	52
Tabulka 12: Altman Sabato model log – rozložení podniků v T-1.....	54
Tabulka 13: Vlastnosti modelu Altman Sabato logaritmický na datech a jeho přesnost	54
Tabulka 14: Úspěšnost bankrotních modelů v čase T-1	56
Tabulka 15: Chybně zařazené podniky v čase T-1	58
Tabulka 16: Bodové hodnocení modelů v čase T-1 na základě chybovosti	59
Tabulka 17: Testované podnikové ukazatele	61
Tabulka 18: Klasifikační funkce pro model $X(n1)(d)$	63
Tabulka 19: Test reprezentativního vzorku pro model $X(n1)(d)$	64
Tabulka 20: Test celkového vzorku pro model $X(n1)(d)$	64
Tabulka 21: Klasifikační funkce pro model $X(n1)(z)$	65
Tabulka 22: Test reprezentativního vzorku pro model $X(n1)(z)$	65
Tabulka 23: Test celkového vzorku pro model $X(n1)(z)$	66
Tabulka 24: Klasifikační funkce pro model $X(n2)(d)$	66
Tabulka 25: Test reprezentativního vzorku pro model $X(n2)(d)$	67
Tabulka 26: Test celkového vzorku pro model $X(n2)(d)$	67
Tabulka 27: Klasifikační funkce pro model $X(n2)(z)$	68
Tabulka 28: Test reprezentativního vzorku pro model $X(n2)(z)$	68
Tabulka 29: Test celkového vzorku pro model $X(n2)(z)$	69
Tabulka 30: Klasifikační funkce pro model $(X(n)+50)(d)$	69

Tabulka 31: Test reprezentativního vzorku pro model $(X(n)+50)(d)$	70
Tabulka 32: Test celkového vzorku pro model $(X(n)+50)(d)$	70
Tabulka 33: Klasifikační funkce pro model $(X(n)+50)(z)$	71
Tabulka 34: Test reprezentativního vzorku pro model $(X(n)+50)(z)$	71
Tabulka 35: Test celkového vzorku pro model $(X(n)+50)(z)$	72
Tabulka 36: Správně zařazené podniky vytvořených modelů v čase T-1.....	72
Tabulka 37: Chybně zařazené podniky vytvořených modelů v čase T-1	73
Tabulka 38: Bodové hodnocení vytvořených modelů v čase T-1.....	73
Tabulka 39: Výsledky diskriminační funkční analýzy pro model $X(n_2)(d)$	74
Tabulka 40: Procentní příspěvek proměnných do modelu.....	75
Tabulka 41: Rozdělení chybně označených podniků.....	75
Tabulka 42: Šedá zóna modelu v čase T-1	76
Tabulka 43: Rozdíl bodového hodnocení s šedou zónou.....	76
Tabulka 44: Vlastnosti modelu s šedou zónou na vzorku dat a jeho přesnost.....	77
Tabulka 45: Výsledky diskriminační funkční analýzy pro model $\log(X(n)+50)(z)$	78
Tabulka 46: Procentní příspěvek proměnných do modelu.....	78
Tabulka 47: Rozdělení chybně označených podniků.....	79
Tabulka 48: Šedá zóna modelu v čase T-1	79
Tabulka 49: Rozdíl bodového hodnocení s šedou zónou.....	80
Tabulka 50: Vlastnosti modelu s šedou zónou na vzorku dat a jeho přesnost.....	80
Tabulka 51: Chybně zařazené podniky vytvořených a vybraných modelů v čase T-1...	81
Tabulka 52: Predikce bankrotu na časových úsecích za jednotlivých modelů	82
Tabulka 53: Celková přesnost na časových úsecích jednotlivých modelů	82